

UNIVERSIDADE FEDERAL DO PARANÁ

YURI MALINOWSKY SHIGA

SISTEMA DE IDENTIFICAÇÃO DE ALIMENTOS BASEADO EM IMAGENS DE  
PORÇÕES ALIMENTARES

CURITIBA

2015

YURI MALINOWSKY SHIGA

SISTEMA DE IDENTIFICAÇÃO DE ALIMENTOS BASEADO EM IMAGENS DE  
PORÇÕES ALIMENTARES

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, Área de Concentração Sistemas Eletrônicos, Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná, como parte das exigências para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Giselle Lopes  
Ferrari Ronque

Coorientador: Prof. Dr. João da Silva Dias

CURITIBA

2015



UNIVERSIDADE FEDERAL DO PARANÁ  
Programa de Pós-Graduação em Engenharia Elétrica  
PPGEE  
Setor de Tecnologia

### ATA DE DEFESA DE MESTRADO

Aos vinte e quatro dias do mês de agosto de 2015, na sala PK 06 do Departamento de Engenharia Elétrica, foi instalada pelo Prof. Dr. Gustavo Henrique da Costa Oliveira, Coordenador do Programa de Pós-Graduação em Engenharia Elétrica, a Banca Examinadora para a centésima septuagésima nona Dissertação de Mestrado do PPGEE, na Área de Concentração em **SISTEMAS ELETRÔNICOS**. Estiveram presentes no ato, além da Coordenadora do Curso de Pós-Graduação, professores, alunos e visitantes.

A Banca Examinadora, atendendo determinação do Colegiado do Programa de Pós-Graduação em Engenharia Elétrica, ficou constituída pelos professores doutores **Giselle Lopes Ferrari Ronque (Orientadora - UFPR); Gustavo Benvenutti Borba (UTFPR); Lucas Ferrari de Oliveira (UFPR); João da Silva Dias (Co-orientador/UFPR) e José Carlos da Cunha (UFPR)**.

Às 14:00 horas, a banca iniciou os trabalhos, convidando o candidato **YURI MALINOWSKY SHIGA** a fazer a apresentação da dissertação intitulada "**SISTEMA DE IDENTIFICAÇÃO DE ALIMENTOS BASEADO EM IMAGENS DE PORÇÕES ALIMENTARES**". Encerrada a apresentação, iniciou-se a fase de arguição pelos membros participantes.

Tendo em vista a dissertação e a arguição, a banca decidiu pela:

☒ **APROVAÇÃO**

☐ **NÃO APROVAÇÃO** do candidato, (de acordo com a determinação da Resolução 63/03-CEPE).

Curitiba, 24 de agosto de 2015.

Prof. Dr. **Giselle Lopes Ferrari Ronque**

Prof. Dr. **Gustavo Benvenutti Borba**

Prof. Dr. **Lucas Ferrari de Oliveira**

Prof. Dr. **João da Silva Dias**

Prof. Dr. **José Carlos da Cunha**



## TERMO DE APROVAÇÃO

Yuri Malinowsky Shiga

### Sistema de Identificação de Alimentos Baseado em Imagens de Porções Alimentares

Dissertação apresentada como requisito parcial para obtenção do grau de  
Mestre no Programa de Pós-Graduação em Engenharia Elétrica da  
Universidade Federal do Paraná.



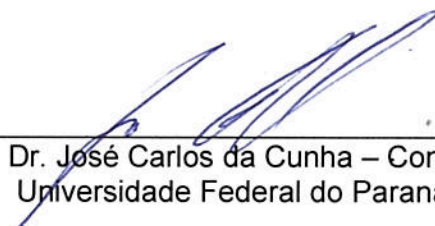
Prof.<sup>a</sup> Dr.<sup>a</sup> Giselle Lopes Ferrari Ronque – Orientadora  
Universidade Federal do Paraná



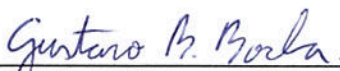
Prof. Dr. João da Silva Dias – Coorientador  
Universidade Federal do Paraná



Prof. Dr. Lucas Ferrari de Oliveira – Convidado  
Universidade Federal do Paraná



Prof. Dr. José Carlos da Cunha – Convidado  
Universidade Federal do Paraná



Prof. Dr. Gustavo Benvenutti Borba – Convidado  
Universidade Tecnológica Federal do Paraná

Curitiba, 24 de Agosto de 2015

## RESUMO

Este trabalho apresenta um sistema capaz de segmentar e classificar alimentos baseado em imagens de porções alimentares. Para o desenvolvimento do sistema, foram adquiridas imagens de 16 alimentos de diferentes grupos alimentares, típicos consumidos pela população brasileira. Para a criação da base de dados utilizada neste trabalho, foram obtidas manualmente 1200 imagens de pratos contendo apenas um alimento, e 60 imagens de pratos contendo diversos alimentos. O sistema proposto neste trabalho é capaz de segmentar os alimentos de uma imagem, utilizando a técnica de crescimento de regiões nos planos vermelho, verde, azul e matiz da imagem. Cada alimento tem suas características extraídas com base na sua coloração e textura. Para a cor foram utilizadas as médias e os desvios padrão dos valores dos pixels nos planos vermelho, verde, azul e matiz da imagem, formando um vetor de características de 8 posições para representar as características de cor. Para a textura foi utilizado o histograma da imagem gerado pelo descritor *local phase quantization* (LPQ), formando um vetor de 255 posições para representar as características de textura. Foi realizada a fusão dos vetores de características de cor e textura, formando um vetor único de características com 263 posições. As características extraídas das imagens de pratos contendo apenas um alimento foram utilizadas para treinar uma rede Bayesiana. Utilizando as técnicas de validação cruzada e conjunto de teste fornecido, testes foram efetuados para validar a eficácia da rede Bayesiana treinada. Com a técnica de validação cruzada, obteve-se um resultado médio de 95,63% de amostras classificadas corretamente. No teste realizado utilizando um conjunto de teste fornecido, foram utilizados os alimentos segmentados de imagens com diversos alimentos no prato, e nesse teste, 240 amostras foram classificadas pela rede Bayesiana, e apenas 23 foram classificadas incorretamente, apresentando 90,42% de taxa de acerto. Um último teste foi realizado em um conjunto de dados ampliado, utilizando a técnica de validação cruzada, obtendo um resultado médio de 96,26% de amostras classificadas corretamente.

Palavras-chave: Crescimento de regiões. LPQ. Processamento digital de imagens. Redes Bayesianas. Classificação de alimentos.

## **ABSTRACT**

This work presents a system to target and classify foods based on food portions of images. To develop the system, 16 food images were acquired from different food groups, typical consumed by the Brazilian population. To create the database used in this study were obtained manually 1200 images of dishes containing only one food, and 60 images of dishes containing various foods. The system proposed in this paper is able to target the food of an image using a region growing technique in red, green, blue and hue image plans. Each food has its characteristics extracted based on its color and texture. For color, the averages and standard deviations of the pixel values in red, green, blue and hue image plans are used, forming a vector of 8 positions to represent the color characteristics. For texture, it was used the histogram of the image generated by the local phase quantization (LPQ) descriptor, forming a vector of 255 positions to represent the texture characteristics. The fusion of the feature vectors of color and texture was performed, forming a single feature vector with 263 positions. The features extracted from the images of dishes containing only one food were used to train a Bayesian network. Using the cross-validation and supplied test set techniques, tests were performed to validate the effectiveness of trained Bayesian network. With the cross-validation technique, there was obtained an average score of 95.63% correctly classified samples. In the test performed using a supplied test set, the foods segmented of images of dishes containing various foods were used, in this test, 240 samples were classified by the Bayesian network, and just 23 were incorrectly classified, presenting 90.42% accuracy rate. A final test was performed on a set of extended data using cross-validation technique, achieving an average score of 96.26% correctly classified samples.

Key words: Region growing. LPQ. Digital image processing. Bayesian networks. Foods classification.

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – DIAGRAMA DE BLOCOS DO SISTEMA COMPLETO APRESENTADO .....	18
FIGURA 2 – PIRÂMIDE ALIMENTAR BRASILEIRA .....	22
FIGURA 3 – CUBO DE CORES RGB .....	25
FIGURA 4 – CONE DE CORES HSV .....	26
FIGURA 5 – ELEMENTO ESTRUTURANTE DE FORMA CIRCULAR E VIZINHANÇA 10.....	29
FIGURA 6 – EXEMPLO DE DILATAÇÃO DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS DILATAÇÃO .....	29
FIGURA 7 – EXEMPLO DE EROÇÃO DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS EROÇÃO .....	30
FIGURA 8 – EXEMPLO DE ABERTURA DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS ABERTURA.....	31
FIGURA 9 – EXEMPLO DE FECHAMENTO DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS FECHAMENTO .....	31
FIGURA 10 – EXEMPLO DO PROCESSO DE PREENCHIMENTO DE BURACOS DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS PREENCHIMENTO DE BURACOS.....	32
FIGURA 11 – EXEMPLO DO PROCESSO DE CRESCIMENTO DE REGIÃO POR AGREGAÇÃO SIMPLES, (a) IMAGEM APRESENTANDO O PIXEL INICIAL, (b) IMAGEM APRESENTANDO OS PIXELS AGREGADOS .....	34
FIGURA 12 – EXEMPLO DA RELAÇÃO ENTRE OS PIXELS DE UMA IMAGEM PARA A CRIAÇÃO DE UMA GLCM.....	36
FIGURA 13 – PROCEDIMENTO SIMPLIFICADO PARA O CÁLCULO DA LPQ .....	38
FIGURA 14 – EXEMPLO DA PARTE QUALITATIVA DE UMA REDE BAYESIANA	42
FIGURA 15 – EXEMPLO DA PARTE QUANTITATIVA DE UMA REDE BAYESIANA .....	43
FIGURA 16 – EXEMPLO DA PARTE QUANTITATIVA DE UMA REDE BAYESIANA CONSIDERANDO QUE O VALOR DA MÉDIA <i>RED</i> POSSUI UM VALOR ENTRE 0 E 80.....	44
FIGURA 17 – FUSÃO EM NÍVEL DE AMOSTRA .....	47

FIGURA 18 – FUSÃO EM NÍVEL DE PRIMITIVA.....	48
FIGURA 19 – EXEMPLIFICAÇÃO DA TÉCNICA DE FUSÃO DE CARACTERÍSTICAS.....	49
FIGURA 20 – FUSÃO EM NÍVEL DE PONTUAÇÃO .....	50
FIGURA 21 – FUSÃO EM NÍVEL DE DECISÃO.....	51
FIGURA 22 – EXEMPLO DA TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO O MÉTODO <i>K-FOLD</i> .....	53
FIGURA 23 – EXEMPLO DE UMA MATRIZ DE CONFUSÃO .....	54
FIGURA 24 – FLUXOGRAMA DA ENTRADA, ESTRUTURA E SAÍDA DO SISTEMA PROPOSTO.....	59
FIGURA 25 – POSICIONAMENTO DA CÂMERA PARA A AQUISIÇÃO DAS IMAGENS OBTIDAS .....	61
FIGURA 26 – PRATOS COM DIFERENTES QUANTIDADES DOS MESMOS ALIMENTOS, (a) ARROZ, (b) FEIJÃO, (c) BETERRABA .....	62
FIGURA 27 – EXEMPLOS DE PRATOS CONTENDO DIVERSOS ALIMENTOS....	62
FIGURA 28 – FLUXOGRAMA DA ETAPA DE PRÉ-PROCESSAMENTO.....	63
FIGURA 29 – PRATO COM PORÇÕES ALIMENTARES ANTES E DEPOIS DO PROCESSO DE ELIMINAÇÃO DO FUNDO, (a) ANTES, (b) DEPOIS.....	64
FIGURA 30 – HISTOGRAMAS DE UMA IMAGEM DE UM PRATO COM ALIMENTOS, (a) HISTOGRAMA DO PLANO VERMELHO, (b) HISTOGRAMA DO PLANO VERDE, (c) HISTOGRAMA DO PLANO AZUL .....	65
FIGURA 31 – (a) IMAGEM DO PRATO COM ALIMENTOS, (b) IMAGEM DOS ALIMENTOS DEPOIS DO PROCESSO DE ELIMINAÇÃO DO PRATO POR CONDIÇÃO LÓGICA .....	66
FIGURA 32 – (a) IMAGEM BINARIZADA DE PORÇÕES ALIMENTARES COM BURACOS, (b) IMAGEM APÓS O PROCESSO DE PREENCHIMENTO DE BURACOS.....	67
FIGURA 33 – (a) IMAGEM ARMAZENADA ANTERIORMENTE, (b) MÁSCARA BINÁRIA, (c) RESULTADO DA APLICAÇÃO DA MÁSCARA BINÁRIA NA IMAGEM .....	67
FIGURA 34 – FLUXOGRAMA DA ETAPA DE SEGMENTAÇÃO .....	68
FIGURA 35 – IMAGEM DE ALIMENTOS E SEUS RESPECTIVOS GRÁFICOS RELACIONANDO A SOMATÓRIA DE PIXELS POR LINHA E POR COLUNA .....	69



FIGURA 36 – IMAGEM DE ALIMENTOS SEGMENTADA E SEUS RESPECTIVOS GRÁFICOS RELACIONANDO A SOMATÓRIA DE PIXELS POR LINHA E POR COLUNA .....	70
FIGURA 37 – PLANOS UTILIZADOS PARA O CRESIMENTO DE REGIÕES: (a) IMAGEM ORIGINAL, (b) PLANO VERMELHO, (c) PLANO VERDE, (d) PLANO AZUL, (e) PLANO MATIZ .....	71
FIGURA 38 – MÁSCARAS OBTIDAS DO CRESCIMENTO DE REGIÃO: (a) PLANO VERMELHO, (b) PLANO VERDE, (c) PLANO AZUL, (d) PLANO MATIZ.....	72
FIGURA 39 – MÁSCARA BINÁRIA RESULTANTE DO PROCESSO DE SEGMENTAÇÃO DE UMA IMAGEM DE PORÇÕES ALIMENTARES .....	73
FIGURA 40 – IMAGEM DO ALIMENTO E IMAGEM RESTANTE GERADAS A PARTIR DO PROCESSO DE SEGMENTAÇÃO.....	73
FIGURA 41 – IMAGENS GERADAS A PARTIR DO PROCESSO DE SEGMENTAÇÃO NA IMAGEM DA FIGURA 40 (b): (a) NOVA IMAGEM DO ALIMENTO, (b) NOVA IMAGEM RESTANTE .....	74
FIGURA 42 – IMAGENS DOS ALIMENTOS E IMAGENS RESTANTES GERADAS A PARTIR DO PROCESSO DE SEGMENTAÇÃO EXECUTANDO DE FORMA RECURSIVA .....	75
FIGURA 43 – (a) IMAGEM DE ALIMENTOS, (b) - (e) SEGMENTOS EXTRAÍDOS COM JSEG, (f) - (j) SEGMENTOS EXTRAÍDOS COM CRESCIMENTO DE REGIÃO .....	76
FIGURA 44 – MATRIZ DE CONFUSÃO DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA.....	87
FIGURA 45 – MATRIZ DE CONFUSÃO DO TESTE REALIZADO UTILIZANDO UM CONJUNTO DE TESTE FORNECIDO .....	91
FIGURA 46 – MATRIZ DE CONFUSÃO DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO .....	95
FIGURA 47 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ALFACE .....	109
FIGURA 48 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ALMÔNDEGA .....	109
FIGURA 49 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ARROZ BRANCO .....	109

FIGURA 50 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO BATATA FRITA .....	110
FIGURA 51 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO BETERRABA.....	110
FIGURA 52 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO BIFE BOVINO NA CHAPA .....	110
FIGURA 53 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO CARNE BOVINA DE PANELA .....	111
FIGURA 54 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO CENOURA .....	111
FIGURA 55 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO FEIJÃO CARIOCA .....	111
FIGURA 56 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO MACARRÃO.....	112
FIGURA 57 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO MAIONESE .....	112
FIGURA 58 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO PEITO DE FRANGO À MILANESA.....	112
FIGURA 59 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO PURÊ DE BATATAS.....	113
FIGURA 60 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ESTROGONOFÉ DE CARNE .....	113
FIGURA 61 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ESTROGONOFÉ DE FRANGO .....	113
FIGURA 62 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO TOMATE .....	114
FIGURA 63 – PRATOS COM DIVERSOS ALIMENTOS.....	114

## LISTA DE TABELAS

TABELA 1 – ALIMENTOS UTILIZADOS NESTE TRABALHO E SEUS GRUPOS DE ALIMENTOS.....	22
TABELA 2 – CONSUMO ALIMENTAR MÉDIO <i>PER CAPITA</i> E PERCENTUAL DE CONSUMO FORA DO DOMICÍLIO DOS ALIMENTOS UTILIZADOS NESTE TRABALHO.....	24
TABELA 3 – MÉDIA E DESVIO PADRÃO DOS ALIMENTOS ADQUIRIDOS PARA A BASE DE DADOS.....	77
TABELA 4 – ALIMENTOS E A QUANTIDADE DE IMAGENS UTILIZADAS PARA O TREINAMENTO DA REDE BAYESIANA .....	79
TABELA 5 – CARACTERÍSTICAS DE MAIOR IMPORTÂNCIA PARA A CLASSIFICAÇÃO DOS ALIMENTOS .....	80
TABELA 6 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO AS CARACTERÍSTICAS DE COR .....	83
TABELA 7 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO AS CARACTERÍSTICAS DE TEXTURA.....	83
TABELA 8 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO A FUSÃO DAS CARACTERÍSTICAS DE COR E TEXTURA .....	84
TABELA 9 – TESTES REALIZADOS COM A TÉCNICA DE VALIDAÇÃO CRUZADA PARA COMPARAR AS CARACTERÍSTICAS DE TEXTURA HARALICK E LPQ.....	85
TABELA 10 – ALIMENTOS TESTADOS E SUAS TAXAS DE ACERTO NO TESTE REALIZADO COM VALIDAÇÃO CRUZADA .....	86
TABELA 11 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC, SENSIBILIDADES E ESPECIFICIDADES DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA .....	88
TABELA 12 – ALIMENTOS E A QUANTIDADE DE AMOSTRAS UTILIZADAS PARA TREINAMENTO E TESTE .....	89
TABELA 13 – ALIMENTOS TESTADOS E SUAS TAXAS DE ACERTO NO TESTE REALIZADO COM CONJUNTO DE TESTE FORNECIDO .....	90

TABELA 14 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC DO TESTE REALIZADO COM CONJUNTO DE TESTE FORNECIDO .....	91
TABELA 15 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO	93
TABELA 16 – ALIMENTOS TESTADOS E SUAS TAXAS DE ACERTO NO TESTE REALIZADO COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO .....	94
TABELA 17 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC, SENSIBILIDADES E ESPECIFICIDADES DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO .....	96
TABELA 18 – COMPARATIVO ENTRE O SISTEMA APRESENTADO NESTE TRABALHO E O SISTEMA DIETCAM .....	97

## LISTA DE SIGLAS

DCNT	– Doenças Crônicas Não Transmissíveis
FAO	– <i>Food and Agriculture Organization</i>
GLCM	– Matriz de Coocorrência dos Níveis de Cinza
HSV	– Sistema de Cores formado por Matiz, Saturação e Brilho
IBGE	– Instituto Brasileiro de Geografia e Estatística
JSEG	– <i>J measure based SEGmentation</i>
LPQ	– <i>Local Phase Quantization</i>
PNA	– Pesquisa Nacional por Amostra de Domicílios
POF	– Pesquisa de Orçamentos Familiares
RB	– Rede Bayesiana
RGB	– Sistema de Cores formado por Vermelho, Verde e Azul
ROC	– <i>Receiver Operating Characteristic</i>
SIFT	– <i>Scale Invariant Feature Transform</i>
STFT	– Transformada de Fourier de Curto Termo
SUS	– Sistema Único de Saúde
TB	– Teorema de Bayes
TCH	– Transformada Circular de Hough
TH	– Transformada de Hough
USDA	– <i>United States Department of Agriculture</i>
WEKA	– <i>Waikato Environment for Knowledge Analysis</i>
WHO	– <i>World Health Organization</i>

## SUMÁRIO

1	INTRODUÇÃO .....	15
1.1	JUSTIFICATIVA .....	17
1.2	OBJETIVOS .....	19
1.2.1	Objetivo Geral.....	19
1.2.2	Objetivos Específicos .....	19
1.3	ESTRUTURA DA DISSERTAÇÃO.....	19
2	FUNDAMENTAÇÃO TEÓRICA.....	20
2.1	NUTRIÇÃO .....	20
2.1.1	Guias Alimentares e a Pirâmide Alimentar Brasileira .....	21
2.1.2	Pesquisa de Orçamentos Familiares .....	23
2.2	PROCESSAMENTO DE IMAGENS.....	24
2.2.1	Modelo de Cores RGB.....	25
2.2.2	Modelo de Cores HSV .....	26
2.2.3	Transformada Circular de Hough.....	27
2.2.4	Operações Morfológicas.....	28
2.2.5	Crescimento de Região ( <i>Region Growing</i> ) .....	33
2.2.6	Descritores de Haralick.....	35
2.2.7	Local Phase Quantization.....	37
2.3	REDES BAYESIANAS .....	39
2.3.1	Parte Qualitativa .....	41
2.3.2	Parte Quantitativa .....	42
2.3.3	Clusterização .....	44
2.4	FUSÃO DE INFORMAÇÕES .....	46
2.4.1	Fusão em Nível de Amostra .....	46
2.4.2	Fusão em Nível de Primitiva .....	48

2.4.3	Fusão em Nível de Pontuação.....	49
2.4.4	Fusão em Nível de Decisão.....	50
2.5	TÉCNICAS DE AVALIAÇÃO .....	52
2.5.1	Validação Cruzada ( <i>Cross-Validation</i> ).....	52
2.5.2	Conjunto de Teste Fornecido ( <i>Supplied Test Set</i> ).....	53
2.5.3	Matriz de Confusão.....	53
2.5.4	Curva ROC .....	54
2.6	Trabalho Relacionado .....	56
3	MATERIAL E MÉTODOS.....	58
3.1	VISÃO GERAL .....	58
3.2	BASE DE DADOS.....	60
3.3	PRÉ-PROCESSAMENTO.....	63
3.4	SEGMENTAÇÃO .....	68
3.5	EXTRAÇÃO DE CARACTERÍSTICAS .....	77
3.6	CLASSIFICAÇÃO.....	78
4	RESULTADOS E DISCUSSÕES.....	82
4.1	TESTES COM VALIDAÇÃO CRUZADA .....	82
4.1.1	Validação Cruzada Utilizando as Características Relacionadas à Cor ..	82
4.1.2	Validação Cruzada Utilizando as Características Relacionadas à Textura	83
4.1.3	Validação Cruzada Utilizando a Fusão das Características .....	84
4.1.4	Discussão dos Testes com Validação Cruzada.....	84
4.2	TESTE COM CONJUNTO DE TESTE FORNECIDO.....	88
4.2.1	Discussão do Teste com Conjunto de Teste Fornecido .....	90
4.3	TESTES COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO .....	92
4.3.1	Discussão dos Testes com Validação Cruzada Utilizando o Conjunto de Dados Ampliado.....	94

4.4	Trabalho Relacionado .....	97
5	CONCLUSÃO .....	99
5.1	TRABALHOS FUTUROS .....	101
	REFERÊNCIAS.....	102
	APÊNDICE .....	109



## 1 INTRODUÇÃO

No decorrer da história, a alimentação estabeleceu importantes etapas no processo evolutivo do homem. No início, o ser humano limitou-se à caça, à pesca e à coleta de vegetais. Posteriormente, a agropecuária permitiu ao homem controlar as técnicas de planejamento da produção dos alimentos, e depois, à produção de excedentes comercializáveis. Com a urbanização, o homem começou a deixar de ingerir os alimentos em seu estado de matéria prima, para consumir os industrializados (CUPPARI, 2002).

Essa evolução humana deu origem ao que se pode chamar de transição nutricional, ou seja, modificações no perfil nutricional da população. Isso é caracterizada pela redução da dominância da desnutrição e aumento da dominância da obesidade (OLIVEIRA, 2004).

Estudos como os de Filho e Rissin (2003) e Bermudez e Tucker (2003) têm demonstrado que o Brasil, além de outros países em desenvolvimento, convive com a transição nutricional, frequentemente determinada pela má-alimentação. Assim, a partir da década de 80, a preocupação até então voltada para a desnutrição, associou-se a outro problema nutricional crescente, a obesidade e suas consequências (ZEFERINO E FILHO, 2003).

A maneira como as populações organizam suas vidas e seu modo de viver foi modificada no decorrer do tempo, devido às transformações econômicas, culturais, políticas e sociais produzidas pelas sociedades. Por facilitar ou dificultar o acesso das populações às condições de vida mais favoráveis à saúde, essas mudanças repercutem diretamente na alteração dos padrões de adoecimento (MALTA et al., 2006).

Considerada como epidemia da atualidade, as doenças crônicas não transmissíveis (DCNT) constituem um sério problema de saúde pública, ameaçando a qualidade de vida de milhões de pessoas e apresentam grande impacto econômico para os países. Entre as principais DCNT estão: obesidade, diabetes e hipertensão arterial (BRASIL, 2011).

Por serem de longa duração, as DCNT são as que mais requerem ações, procedimentos e serviços de saúde, gerando no Brasil uma sobrecarga do Sistema Único de Saúde (SUS). Malta et al. (2006) estimam que os gastos do Ministério da

Saúde com atendimentos ambulatoriais e internações em função das DCNT sejam de aproximadamente R\$ 7,5 bilhões por ano.

De acordo com a Organização Mundial da Saúde, mais de 36 milhões de pessoas morrem anualmente de DCNT, sendo que 14 milhões dessas mortes ocorrem em pessoas com menos de 70 anos (WHO, 2013).

No Brasil, aproximadamente 72% das mortes são causadas pelas DCNT, atingindo principalmente as camadas pobres da população, como a população de baixa escolaridade e renda (MALTA et al., 2011).

Dados da Pesquisa Nacional por Amostra de Domicílios (PNA), realizada em 2008, mostram que o número de indivíduos com 65 anos ou mais que relataram apresentar pelo menos um tipo de DCNT chegava a 79,1% (IBGE, 2010).

De forma geral, as doenças crônicas não transmissíveis são as que mais demandam ações, procedimentos e serviços de saúde. Sendo, portanto, responsáveis por altas taxas de mortalidade e por cerca de mais de 70% dos gastos assistenciais com a saúde no Brasil (OPAS, 2012).

De acordo com o Ministério da Saúde do Brasil, o sobrepeso e a obesidade resultantes da falta de uma alimentação saudável são um dos principais fatores de risco evitáveis de DCNT, cujo controle tem um efeito substantivo na redução de mortes prematuras e de incapacidades decorrentes de doenças cardiovasculares e diabetes (BRASIL, 2011).

Para atingir o estado nutricional adequado, deve-se, primeiramente, avaliar o consumo alimentar, pois com a obtenção de dados referentes à alimentação de indivíduos e populações, é possível realizar o diagnóstico e a intervenção nutricional, contribuindo para a saúde e qualidade de vida (KIM E KIM, 2010).

Dentre as ferramentas de avaliação de consumo alimentar, destacam-se os inquéritos alimentares, os quais possuem baixo custo de aplicação, não são invasivos e podem fornecer diversas informações fundamentais sobre a alimentação (ASSIS et al., 2009).

Os inquéritos alimentares são métodos de avaliação utilizados para estimar a quantidade e a frequência de alimentos consumidos de um indivíduo durante um período de tempo. Os principais objetivos dos inquéritos alimentares são: investigar a relação entre estado nutricional e saúde, identificar padrões de consumo e planejar políticas e programas de intervenção (FISBERG et al., 2005).

Por meio dos inquéritos alimentares, é possível observar os hábitos alimentares inadequados com a finalidade de corrigi-los e, além disso, implantar programas de educação alimentar, como forma de prevenção das DCNT (HOLANDA E FILHO, 2006).

Aplicações de telefonia móvel têm surgido para auxiliar na questão dos inquéritos alimentares, porém a maioria delas usa apenas o telefone como um diário alimentar, necessitando de uma alta interação do usuário com a aplicação. Mesmo com o auxílio das câmeras dos aparelhos para registrar os alimentos a serem consumidos, os usuários têm que analisar manualmente os resultados da imagem processada (KONG E TAN, 2012).

Com os avanços da ciência e da tecnologia a computação está cada vez mais presente nas diversas áreas da atividade humana, desempenhando uma importante ferramenta nos processos de coleta, armazenamento e análise de informações (ALVES et al., 2006).

A riqueza de informações na área da nutrição constitui um material a ser empregado no campo da tecnologia, devido às vantagens da utilização de um sistema informatizado, tais como: confiabilidade dos resultados, rápido processamento de informações e armazenamento de dados (ANÇÃO, 2001).

## 1.1 JUSTIFICATIVA

No dia 19 de junho de 2013, entrou em vigor no Paraná a lei estadual 17604, determinando que bares, restaurantes, hotéis, *fast-foods* e similares devem obrigatoriamente manter à disposição do consumidor, o cardápio contendo todos os itens comercializados com a respectiva quantidade de calorias a serem adquiridas na ingestão dos produtos, bem como a presença de lactose e glúten nos alimentos (PARANÁ, 2013). Porém, em restaurantes, não é possível calcular com exatidão as calorias do prato com alimentos, mesmo que seja fornecido o valor calórico de cada porção alimentar.

Uma proposta contributiva para a área da nutrição é um sistema capaz de analisar os valores calóricos das refeições consumidas por um indivíduo, utilizando uma imagem obtida através de uma câmera digital ou celular. Contudo, em um primeiro momento, os alimentos presentes no prato tem que ser identificados, para

posteriormente afirmar as calorias desses alimentos. O sistema apresentado nesse trabalho se preocupa com a identificação dos alimentos. O diagrama de blocos do sistema completo é apresentado na FIGURA 1.

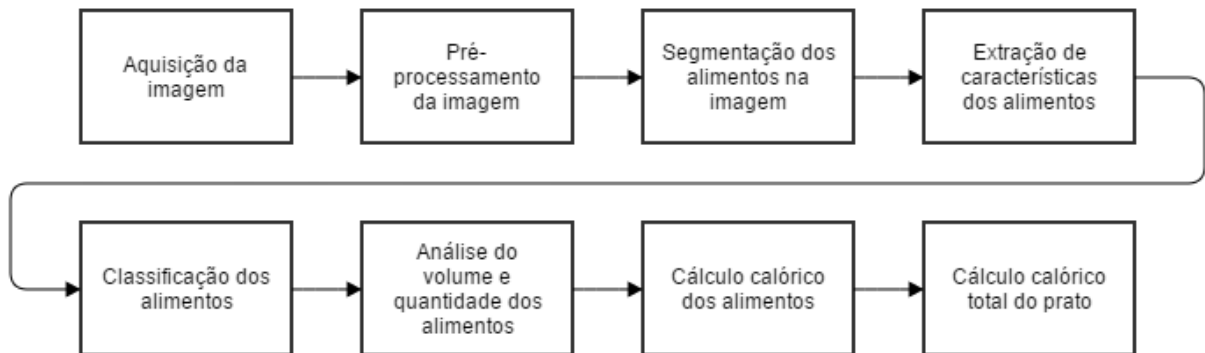


FIGURA 1 – DIAGRAMA DE BLOCOS DO SISTEMA COMPLETO APRESENTADO  
FONTE: O autor (2015)

A primeira etapa do sistema é a aquisição da imagem de um prato com alimentos, obtida através de uma câmera digital ou celular. A segunda etapa é pré-processar a imagem obtida, removendo todo o conteúdo que não seja alimento. A terceira etapa é separar os diferentes alimentos encontrados na imagem. A quarta etapa é a extração das características de cor e textura de cada alimento segmentado. A quinta etapa é classificar cada alimento no prato. A sexta etapa é a verificação da quantidade de cada alimento no prato, e o cálculo do volume desses alimentos. A sétima etapa é o cálculo calórico, ou seja, baseado em quais alimentos estão no prato e suas respectivas quantidades, calcula-se o valor calórico de cada porção alimentar. A oitava etapa é o total da soma dos cálculos calóricos obtido na etapa anterior, a fim de informar ao usuário a quantidade de calorias a serem adquiridas na ingestão dos alimentos.

A contribuição deste trabalho consiste nas cinco primeiras etapas do sistema mencionado, isto é, a aquisição, o pré-processamento e a segmentação da imagem, a extração de características e a classificação dos diferentes alimentos contidos na imagem. Com o objetivo de auxiliar o processo de inquéritos alimentares e visando, futuramente, um sistema capaz de analisar os valores energéticos das refeições consumidas por um indivíduo.

## 1.2 OBJETIVOS

### 1.2.1 Objetivo Geral

Este trabalho tem como objetivo geral a concepção de um sistema com a capacidade de segmentar e classificar diferentes alimentos, baseado em imagens de pratos com porções alimentares, obtidas por meio de uma câmera de celular, utilizando técnicas de processamento de imagens e de inteligência artificial.

### 1.2.2 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- avaliar e definir as características relevantes presentes em imagens de porções alimentares, visando identificar as melhores técnicas de processamento de imagens capazes de separar e classificar cada alimento presente em um prato;
- implementar um sistema para segmentação, extração de características e classificação de imagens de porções alimentares;
- determinar as taxas de acerto e o desempenho do sistema por meio da execução de testes.

## 1.3 ESTRUTURA DA DISSERTAÇÃO

Este documento é composto primeiramente por este capítulo de introdução, objetivos e a proposta desta dissertação. No Capítulo 2 é apresentada a fundamentação teórica relacionada à pesquisa, incluindo todas as técnicas utilizadas neste trabalho. Em seguida, no Capítulo 3 são expostos os materiais e métodos, juntamente com as técnicas utilizadas no desenvolvimento do sistema. Dando sequência, no Capítulo 4 são apresentados os resultados e discussão e o Capítulo 5 exhibe as conclusões obtidas e os trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta inicialmente os conceitos da nutrição, a pirâmide alimentar brasileira e a pesquisa de orçamentos familiares. Em seguida, são apresentadas as técnicas utilizadas neste trabalho, entre elas as técnicas de processamento de imagens, fusão de informações, redes Bayesianas e de avaliação utilizadas na análise dos resultados.

### 2.1 NUTRIÇÃO

Nutrição é a ciência *“que estuda os alimentos, seus nutrientes, sua ação, interação e balanço em relação à saúde e doença, além dos processos pelos quais o organismo ingere, absorve, transporta, utiliza e excreta os nutrientes”*, conforme Cuppari (2002).

Pedro Escudero, médico argentino, estabeleceu em 1937, as Leis da Alimentação, que definem a alimentação equilibrada como sendo “quantitativamente suficiente, qualitativamente completa, além de harmoniosa em seus componentes, e adequada à sua finalidade e ao organismo a que se destina” (VASCONCELOS, 2002).

Do ponto de vista nutricional, o ser humano é biologicamente frágil e ao mesmo tempo exigente, pois necessita de uma alimentação equilibrada que promova benefícios para a manutenção de sua saúde (CUPPARI, 2002).

A seleção dos alimentos é um processo complexo devido ao componente comportamental que determina a escolha de alimentos, pois com a ausência de alimentos é provável que ocorram deficiências, por outro lado, o excesso de alimentos não assegura ótima nutrição (FISBERG et al., 2005).

Atitudes com relação aos alimentos variam de acordo com a diversidade geográfica e os hábitos regionais, onde ocorre o preparo e o consumo da refeição (dentro ou fora do domicílio), refletindo-se no padrão e no tamanho das porções (PHILIPPI, 2008).

Assim, por meio de uma alimentação variada em quantidades adequadas, pode-se obter uma dieta equilibrada, ou seja, proporcionando os nutrientes necessários para atender as necessidades do organismo (PHILIPPI, 2008).

Observa-se que as sociedades modernas e industrializadas, tendem para um padrão dietético com alto conteúdo de gorduras, colesterol, açúcar, carboidratos refinados, baixo teor de ácidos graxos insaturados e de fibra, tudo isso ligado ao aumento de vida sedentária, resultando no incremento da obesidade e surgimento de doenças crônicas não transmissíveis (FISBERG et al., 2005).

Assim, baseado no conceito de Segurança Alimentar e Nutricional e nas práticas alimentares saudáveis, deve-se garantir condições de acesso aos alimentos básicos, com qualidade e quantidade suficiente, de forma permanente e sem comprometer o acesso a outras necessidades essenciais que contribuem com existência digna em um contexto de desenvolvimento integral e saudável (PHILIPPI, 2008).

#### 2.1.1 Guias Alimentares e a Pirâmide Alimentar Brasileira

Os guias alimentares são instrumentos que fornecem informações à população visando promover a saúde e hábitos alimentares saudáveis. Devem ser representados por grupos de alimentos e são baseados principalmente na relação existente entre os alimentos e a saúde dos indivíduos (WHO/FAO, 2003).

No início dos anos 90, com a publicação do guia alimentar americano, surgiram os primeiros grupos alimentares, baseados na variedade de informações existentes e incluindo a relação entre os alimentos e a saúde dos indivíduos. Em 1992, o *United States Department of Agriculture* (USDA) adotou como ícone o formato de pirâmide (PHILIPPI, 2008).

A Pirâmide dos Alimentos é um instrumento de orientação nutricional utilizado por profissionais da saúde, com o objetivo de promover mudanças de hábitos alimentares, visando à saúde global e à prevenção de doenças. Esse ícone foi considerado uma representação gráfica que facilita a visualização dos alimentos, assim como a sua escolha nas refeições diárias (WELSH et al., 1992).

Considerando a repercussão favorável desta apresentação dos alimentos em grupos, distribuídos na pirâmide, foi desenvolvida por Philippi et al. (1999) uma adaptação da proposta americana para o Brasil, apresentada na FIGURA 2.



FIGURA 2 – PIRÂMIDE ALIMENTAR BRASILEIRA  
FONTE: Adaptado de Philippi (2008)

A Pirâmide Alimentar Brasileira é a representação gráfica oficial do Ministério da Saúde para promover o bem estar nutricional da população. De acordo com Philippi (2008), a ferramenta pode ser utilizada como material de apoio para o desenvolvimento de outros conteúdos educativos e estratégias de intervenção nutricional.

Para o desenvolvimento deste trabalho, foram adquiridas imagens de 16 alimentos, comumente encontrados em restaurantes comerciais, de diferentes grupos de alimentos que compõe a Pirâmide dos Alimentos Brasileira. A TABELA 1 apresenta os alimentos selecionados e seus respectivos grupos de alimentos.

TABELA 1 – ALIMENTOS UTILIZADOS NESTE TRABALHO E SEUS GRUPOS DE ALIMENTOS

Alimento	Grupo de Alimentos
Alface	Grupo das verduras e legumes
Almôndega	Grupo das carnes e ovos
Arroz Branco	Grupo do arroz, pão, massa, batata e mandioca
Batata Frita	Grupo dos óleos e gorduras
Beterraba	Grupo das verduras e legumes
Bife Bovino na Chapa	Grupo das carnes e ovos

continua



TABELA 1 – ALIMENTOS UTILIZADOS NESTE TRABALHO E SEUS GRUPOS DE ALIMENTOS  
continuação

Alimento	Grupo de Alimentos
Carne Bovina de Panela	Grupo das carnes e ovos
Cenoura	Grupo das verduras e legumes
Feijão Carioca	Grupo dos feijões e oleaginosas
Macarrão	Grupo do arroz, pão, massa, batata e mandioca
Maionese	Grupo do arroz, pão, massa, batata e mandioca
Peito de Frango a Milanesa	Grupo das carnes e ovos
Purê de Batatas	Grupo do arroz, pão, massa, batata e mandioca
Estrogonofe de Carne	Grupo das carnes e ovos
Estrogonofe de Frango	Grupo das carnes e ovos
Tomate	Grupo das verduras e legumes

FONTE: O autor (2015)

Dos oito grupos que compõe a Pirâmide dos Alimentos, foi possível abranger cinco deles. Os grupos das frutas; leite, queijo e iogurte; e açúcar e doces não foram contemplados, pois o intuito deste trabalho é validar o sistema proposto para alimentos que são possíveis de serem combinados e assim formarem um prato a ser consumido por um indivíduo.

### 2.1.2 Pesquisa de Orçamentos Familiares

A Pesquisa de Orçamentos Familiares (POF) é um estudo multicêntrico realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) juntamente com o Ministério da Saúde, onde mais de 60 mil domicílios brasileiros foram entrevistados, com o objetivo de analisar o perfil nutricional da população brasileira (IBGE, 2010).

Na Pesquisa de Orçamentos Familiares, os alimentos possuem nomenclaturas generalizadas, que abrangem um ou mais alimentos utilizados neste trabalho. Para exemplificar, a TABELA 2 apresenta cada alimento utilizado neste trabalho, o nome do respectivo alimento na POF, seu consumo alimentar médio *per capita* e o percentual de consumo fora do domicílio em relação ao total consumido.

TABELA 2 – CONSUMO ALIMENTAR MÉDIO *PER CAPITA* E PERCENTUAL DE CONSUMO FORA DO DOMICÍLIO DOS ALIMENTOS UTILIZADOS NESTE TRABALHO

Alimento na POF	Alimento utilizado no trabalho	Consumo alimentar médio <i>per capita</i>	Percentual de consumo fora do domicílio em relação ao total consumido
Arroz	Arroz Branco	160,3 g/dia	12,5%
Feijão	Feijão Carioca	182,9 g/dia	12,2%
Alface	Alface	3,6 g/dia	20,7%
Salada crua	Alface / Cenoura / Beterraba	14,8 g/dia	18,8%
Cenoura	Cenoura	0,9 g/dia	19,8%
Tomate	Tomate	6,5 g/dia	15,5%
Outros legumes	Beterraba	4,6 g/dia	13,2%
Batata-inglesa	Purê de Batatas / Maionese	14,7 g/dia	19,1%
Batata-inglesa frita	Batata Frita	0,5 g/dia	31,9%
Macarrão e preparações à base de macarrão	Macarrão	36,3 g/dia	15,5%
Carne bovina	Almôndega / Bife na Chapa / Carne de Panela / Estrogonofe de Carne	63,2 g/dia	16,6%
Preparações à base de carne bovina	Estrogonofe de Carne	3,0 g/dia	23,7%
Aves	Peito de Frango a Milanesa / Estrogonofe de Frango	36,5 g/dia	17,0%
Preparações à base de aves	Estrogonofe de Frango	0,9 g/dia	26,5%

FONTE: Adaptado de IBGE (2010)

Com isso, é possível considerar que os alimentos escolhidos para a execução deste trabalho são considerados típicos consumidos pela população brasileira.

## 2.2 PROCESSAMENTO DE IMAGENS

Nessa seção será explicado o conceito dos modelos de cores, em seguida serão listadas as técnicas de processamento de imagens utilizadas no desenvolvimento deste trabalho. A transformada circular de Hough e uma função baseada em reconstrução morfológica foram utilizados para pré-processar as imagens. Um algoritmo de crescimento de região foi utilizado em diversos planos da imagem a fim de segmentar as imagens. Por fim, os descritores de Haralick foram

utilizados primeiramente como descritores de textura dos alimentos testados. Porém, o *Local Phase Quantization* (LPQ) acabou sendo utilizado como descritor de textura definitivo.

### 2.2.1 Modelo de Cores RGB

O modelo de cores RGB é utilizado nos dispositivos de saída gráfica com três cores primárias: vermelho, verde e azul. A sigla RGB deriva da junção das primeiras letras dos nomes destas cores primárias na língua inglesa: *red*, *green* e *blue* (LOPES, 2013).

Tradicionalmente, as implementações do modelo RGB nos sistemas gráficos empregam valores inteiros entre 0 e 255 para representar o valor da intensidade de cada componente. O valor 0 corresponde à intensidade mínima com que a cor pode ser apresentada, e o valor 255 corresponde à intensidade máxima.

Conforme Souto (2000), a cor branca é resultante da adição simultânea das três cores primárias com intensidade máxima. Já a cor preta é obtida quando todas as cores primárias apresentam intensidade mínima.

O espaço de cores RGB é tradicionalmente representado através de uma figura geométrica denominada de “cubo de cores”, apresentado na FIGURA 3.




FIGURA 3 – CUBO DE CORES RGB  
FONTE: Adaptado de Charles Poynton (2003)

Os vértices do cubo de cores representam as cores aditivas primárias e secundárias, com exceção dos vértices referentes ao preto e ao branco, cuja diagonal que os liga estão localizados os tons de cinza.

Neste trabalho, as médias dos valores RGB dos pixels dos alimentos e seus respectivos desvios padrão foram utilizadas como parte das características de cor.

### 2.2.2 Modelo de Cores HSV

Inventado por Alvy Ray Smith em 1978, o modelo de cores HSV é mais intuitivo que o modelo de cores RGB. HSV é a abreviatura para o sistema de cores formadas pelas componentes *hue* (matiz ou tonalidade), *saturation* (saturação) e *value* (valor ou brilho) (SEVERINO, 2009).

O espaço de cores HSV é tradicionalmente representado através de uma figura geométrica denominada de “cone de cores”, apresentado na FIGURA 4.




FIGURA 4 – CONE DE CORES HSV  
FONTE: Adaptado de Russ (2011)

O matiz é relacionado à cor em si, e define a tonalidade dominante de uma área, abrangendo todas as cores do espectro. O matiz atinge valores de 0 a 360, sendo cada um desses valores, um ângulo no círculo da base do cone de cores HSV.

A saturação de uma cor, também chamada de grau de pureza, é o parâmetro que especifica a qualidade do matiz, pelo grau de mesclagem do matiz

com a cor branca. Seus valores variam entre 0 e 1. Uma saturação de 1 significa que a cor é pura, ou seja, não há a mistura da cor branca com a cor em questão. Já uma saturação de 0 significa que a cor é totalmente branca e, nesse caso, o valor do matiz se torna irrelevante.

O parâmetro valor corresponde à intensidade da cor e varia entre 0 e 1, sendo 1 uma intensidade máxima, e 0 uma intensidade nula, tornando irrelevantes os valores do matiz e da saturação. Isto é, quando o parâmetro valor é igual a 0, a cor apresentada é o preto absoluto.

Neste trabalho a média e o desvio padrão dos valores do plano matiz dos pixels dos alimentos foram utilizadas como algumas das características de cor.

### 2.2.3 Transformada Circular de Hough

Proposta por Paul Hough em 1962, a Transformada de Hough (TH) é uma técnica de extração de características usada em análise de imagens, visão computacional e processamento digital de imagens (SHAPIRO E STOCKMAN, 2001).

Geralmente, a Transformada de Hough é aplicada após a imagem passar por um processo de detecção de bordas. Com isso, somente os pixels da imagem referentes às bordas são utilizados no processamento.

A Transformada de Hough é uma técnica utilizada em aplicações que envolvem a detecção e a determinação dos parâmetros de objetos geométricos simples em imagens digitais, como retas, círculos e elipses (GONZALEZ E WOODS, 2007). A técnica utilizada para detectar círculos é conhecida como Transformada Circular de Hough (TCH).

A Transformada Circular de Hough tem como objetivo encontrar formações circulares, de um determinado raio  $R$ , dentro de uma imagem (ATHERTON E KERBYSON, 1999).

Para o cálculo da TCH, são desenhados vários círculos variando a coordenada de centro  $(x, y)$  e o raio  $r$  utilizando as suas equações polares:

$$x_0 = x - r \cos \theta \quad (1)$$

$$y_0 = y - r \sin \theta \quad (2)$$

em que  $x_0$  e  $y_0$  são as coordenadas do centro de um círculo,  $x$  e  $y$  são pontos quaisquer da imagem,  $r$  é o raio do círculo e  $\theta$  é o ângulo desse raio com o eixo  $x$  (MACEDO, 2012).

Para cada um desses círculos desenhados, seus pontos são comparados com as coordenadas da imagem. Caso uma coordenada corresponda a um pixel com nível de cinza diferente de zero, a célula na matriz que corresponde aos parâmetros desse círculo é incrementada em uma unidade.

Ao final desse processo a posição da matriz com valor máximo corresponde ao conjunto de parâmetros do círculo que melhor se encaixa na imagem. Em resumo, o algoritmo consiste em buscar em toda a imagem, círculos com um determinado raio.

Como exemplos de utilização desta técnica, pode-se verificar o trabalho de Leung e Huang (1991) que utilizaram a TCH para detectar e localizar, com eficácia, as rodas de um veículo em imagens. D'Orazio et al. (2004) desenvolveram um algoritmo usando a TCH e classificadores neurais para identificar a bola em sequências de imagens de jogos de futebol, com o objetivo de verificar quando um gol é marcado, com resultados superiores a 92% nos testes realizados.

#### 2.2.4 Operações Morfológicas

A base da morfologia matemática se apoia no princípio da análise da estrutura geométrica das imagens, isso é feito através do uso de um conjunto conhecido como elemento estruturante. O elemento estruturante é um conjunto completamente definido e conhecido pelo computador em forma e tamanho, que é comparado, a partir de uma transformação, aos conjuntos desconhecidos da imagem (FACON, 1996). A FIGURA 5 apresenta um exemplo de um elemento estruturante de forma circular e vizinhança 10.




FIGURA 5 – ELEMENTO ESTRUTURANTE DE FORMA CIRCULAR E VIZINHANÇA 10  
FONTE: O autor (2015)

Segundo Soille (1999), existem duas operações básicas para a morfologia matemática: a dilatação e a erosão.

A dilatação de um objeto aumenta sua área geométrica, marcando os pixels de fundo que são adjacentes ao contorno do objeto, com o valor dos pixels do objeto (SOILLE, 1999). A FIGURA 6 mostra um exemplo de uma imagem binária em (a), e a mesma imagem após passar pelo processo de dilatação em (b), com elemento estruturante de forma circular e vizinhança 10.




FIGURA 6 – EXEMPLO DE DILATAÇÃO DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS DILATAÇÃO  
FONTE: O autor (2015)

A dilatação é o processo onde todos os pontos que tocam o objeto pelo lado de fora são incorporados ao objeto, resultando em um aumento da área do objeto. A dilatação é muito usada no preenchimento de buracos e objetos segmentados.

A erosão de um objeto reduz sua área geométrica, marcando os pixels do contorno do objeto com o valor dos pixels de fundo (SOILLE, 1999). A FIGURA 7 apresenta um exemplo de uma imagem binária em (a), e a mesma imagem após passar pelo processo de erosão em (b), com elemento estruturante de forma circular e vizinhança 10.




FIGURA 7 – EXEMPLO DE EROSÃO DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS EROSÃO  
FONTE: O autor (2015)

A erosão simples é o processo onde todos os pontos que estão no contorno do objeto são eliminados, resultando em uma diminuição da área do objeto. A erosão é muito utilizada para remover objetos que não são de interesse, de um segmento de imagem.

A dilatação e a erosão fornecem condições básicas para a elaboração de outros filtros morfológicos, como abertura e fechamento (SOILLE, 1999).

A abertura nivela os contornos pelo interior, separa os objetos, elimina partículas de tamanho inferior ao elemento estruturante, com a vantagem de que os elementos restantes na imagem ficam quase idênticos às originais, mas o conjunto aberto é menos rico em detalhes que o conjunto original (SOILLE, 1999). A FIGURA 8 apresenta um exemplo de uma imagem binária em (a), e a mesma imagem após passar pelo processo de abertura em (b), com elemento estruturante circular e 10 interações.






FIGURA 8 – EXEMPLO DE ABERTURA DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS ABERTURA  
FONTE: O autor (2015)

O processo de abertura se resume na aplicação de uma erosão, imediatamente seguida de uma dilatação utilizando o mesmo elemento estruturante.

O fechamento suaviza as bordas no exterior e preenche os buracos no interior das partículas de tamanho inferior ao elemento estruturante, os objetos restantes ficam quase idênticos aos originais, mas o conjunto fechado é menos rico em detalhes que o conjunto inicial (SOILLE, 1999). A FIGURA 9 apresenta um exemplo de uma imagem binária em (a), e a mesma imagem após passar pelo processo de fechamento em (b), com elemento estruturante circular e 10 interações.




FIGURA 9 – EXEMPLO DE FECHAMENTO DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS FECHAMENTO  
FONTE: O autor (2015)

O processo de fechamento se resume na aplicação de uma dilatação, imediatamente seguida de uma erosão utilizando o mesmo elemento estruturante.

Neste trabalho, operações realizadas para remover elementos indesejáveis da imagem, conseqüentemente acabam removendo alguns elementos importantes da mesma, criando alguns espaços vazios na imagem. Esses espaços vazios são chamados de buracos (*holes*).

Um buraco pode ser entendido como uma região de pixels escuros contornada por um conjunto de pixels mais claros. O preenchimento de buracos pode ser realizado por intermédio da operação morfológica e por operações de interseção e complementação de conjuntos (SOILLE, 1999).

Para isso, a função “imfill” do MATLAB® é utilizada com o parâmetro *holes*, com o objetivo de preencher esses buracos, conforme apresenta a FIGURA 10.




FIGURA 10 – EXEMPLO DO PROCESSO DE PREENCHIMENTO DE BURACOS DE UMA IMAGEM, (a) IMAGEM ORIGINAL, (b) IMAGEM APÓS PREENCHIMENTO DE BURACOS  
FONTE: O autor (2015)

Na FIGURA 10, a imagem em (a) passou pelo processo de preenchimento de buracos, resultando a imagem em (b), preservando o tamanho e os detalhes na borda.

### 2.2.5 Crescimento de Região (*Region Growing*)

O crescimento de região, apresentado pela primeira vez por Adams e Bischof (1994), tem como objetivo mapear pixels individuais de uma imagem em um conjunto de pixels. Segmentando assim a região obtida do resto da imagem.



Em processamento digital de imagens, segmentação se refere ao processo de subdividir uma imagem em múltiplas regiões ou objetos constituintes. Em geral, a segmentação pode ser considerada uma das mais difíceis tarefas em visão computacional (GONZALEZ E WOODS, 2007). Pois, a segmentação da imagem é basicamente um problema de percepção psicofísica, e, portanto, não suscetível de uma solução puramente analítica (PAVLIDIS, 1977).

No crescimento de região, o método de processamento mais simples é a agregação de pixels, isto é, escolhe-se um pixel ou um conjunto de pixels denominados “sementes” e faz-se o crescimento da região através da agregação de pixels vizinhos às sementes que possuem propriedades similares. O processo continua até se atingir uma condição preestabelecida de parada, como por exemplo, um determinado nível de cinza ou uma distância específica (KALLERGI et al., 1992).

Conforme explica Wu et al. (2008), dado o ponto inicial (semente), o método de crescimento de região procura os vizinhos desse ponto inicial para determinar se eles pertencem à mesma região. Caso afirmativo, os vizinhos desses pontos também são pesquisados, e assim sucessivamente.

Esse processo é executado de forma recursiva até que não haja mais vizinhos para serem adicionados à região, ou até que o crescimento atinja uma distância máxima predeterminada.

A FIGURA 11 exemplifica esse processo utilizando um nível de limiar absoluto de 5 pixels, isto é, a partir do ponto semente marcado em amarelo em (a), o algoritmo busca os pixels vizinhos do pixel inicial e agrega todos os pixels em que a diferença entre seus valores e o valor do pixel inicial seja menor que o valor do limiar absoluto.

-  - Pixel inicial (semente)
-  - Pixels agregados com o crescimento de região

36	34	30	37	44	44	57	62	63	59	64	59	61	64	58
35	40	34	42	40	42	56	61	60	61	58	63	62	61	65
30	30	37	44	52	47	53	50	48	62	65	62	59	60	62
38	32	43	44	54	49	51	46	55	57	63	60	64	62	57
44	37	42	45	54	49	53	48	51	55	52	64	56	56	63
42	41	44	50	48	52	55	51	45	49	47	62	58	57	56
33	42	44	52	47	51	50	48	45	53	46	54	49	59	64
41	39	45	46	54	45	50	50	53	49	47	52	48	65	59
34	33	39	46	53	47	51	52	58	54	55	50	49	58	60
39	40	33	41	43	42	50	45	49	51	46	65	60	63	61
41	37	33	35	38	39	40	41	53	54	47	57	57	61	60
32	34	35	39	33	32	64	60	63	59	62	61	63	60	58
37	35	34	33	36	37	60	59	65	61	58	56	65	58	57
38	31	35	32	35	45	40	39	38	40	42	44	48	50	51
34	30	36	31	30	30	31	35	39	40	41	43	48	49	53

(a)

36	34	30	37	44	44	57	62	63	59	64	59	61	64	58
35	40	34	42	40	42	56	61	60	61	58	63	62	61	65
30	30	37	44	52	47	53	50	48	62	65	62	59	60	62
38	32	43	44	54	49	51	46	55	57	63	60	64	62	57
44	37	42	45	54	49	53	48	51	55	52	64	56	56	63
42	41	44	50	48	52	55	51	45	49	47	62	58	57	56
33	42	44	52	47	51	50	48	45	53	46	54	49	59	64
41	39	45	46	54	45	50	50	53	49	47	52	48	65	59
34	33	39	46	53	47	51	52	58	54	55	50	49	58	60
39	40	33	41	43	42	50	45	49	51	46	65	60	63	61
41	37	33	35	38	39	40	41	53	54	47	57	57	61	60
32	34	35	39	33	32	64	60	63	59	62	61	63	60	58
37	35	34	33	36	37	60	59	65	61	58	56	65	58	57
38	31	35	32	35	45	40	39	38	40	42	44	48	50	51
34	30	36	31	30	30	31	35	39	40	41	43	48	49	53

(b)

FIGURA 11 – EXEMPLO DO PROCESSO DE CRESCIMENTO DE REGIÃO POR AGREGAÇÃO SIMPLES, (a) IMAGEM APRESENTANDO O PIXEL INICIAL, (b) IMAGEM APRESENTANDO OS PIXELS AGREGADOS  
 FONTE: O autor (2015)

No caso observado na FIGURA 11, o nível de limiar absoluto é de 5 pixels e o valor do pixel inicial é 50, então o algoritmo agregou todos os pixels vizinhos que possuem os valores entre 45 e 55, como é possível observar em (b).

Devido a seus resultados eficientes para imagens reais, este método é utilizado de diversas maneiras. Deng et al. (2010), por exemplo, utilizaram o algoritmo de crescimento de região em um estudo preliminar para possibilitar a detecção de tumores cerebrais em imagens por ressonância magnética.

O algoritmo de crescimento de região utilizado neste trabalho foi o *Region Growing (2D/3D grayscale)* desenvolvido por Kellner (2011) e implementado em MATLAB®. Esse é um algoritmo recursivo para conjuntos de imagens em tons de cinza 2D e 3D, tendo como saída uma máscara binária contendo os pixels agregados no crescimento de região.

Para a segmentação dos alimentos das imagens neste trabalho, o algoritmo de crescimento de região foi utilizado em quatro planos diferentes da imagem: vermelho, verde, azul e matiz. Os planos RGB foram escolhidos por serem os planos de uma imagem digital (LOPES, 2013). Enquanto o plano matiz foi utilizado por definir a tonalidade (cor) dominante da imagem.

#### 2.2.6 Descritores de Haralick

Os descritores de Haralick são compostos por características que podem ser extraídas de uma imagem digital para representar texturas. Estas características são obtidas através da utilização de matrizes de coocorrência de níveis de cinza, do inglês *gray level co-occurrence matrix* (GLCM) (HARALICK et al., 1973).

A GLCM é uma representação matricial da frequência com que diferentes combinações de brilho ocorrem em uma imagem. A relação entre combinações de brilho é determinada comparando-se um pixel de referência a um pixel vizinho. O pixel vizinho é determinado por dois parâmetros: a distância e o ângulo em relação ao pixel de referência (HARALICK E SHAPIRO, 1992). A FIGURA 12 mostra um exemplo da relação entre os pixels de uma imagem para a criação de uma GLCM.

Pixel Vizinho 3 Distância = 1 Ângulo = 135°	Pixel Vizinho 2 Distância = 1 Ângulo = 90°	Pixel Vizinho 1 Distância = 1 Ângulo = 45°
Pixel Vizinho 4 Distância = 1 Ângulo = 0°	Pixel Referência	Pixel Vizinho 0 Distância = 1 Ângulo = 0°
Pixel Vizinho 5 Distância = 1 Ângulo = 45°	Pixel Vizinho 6 Distância = 1 Ângulo = 90°	Pixel Vizinho 7 Distância = 1 Ângulo = 135°

FIGURA 12 – EXEMPLO DA RELAÇÃO ENTRE OS PIXELS DE UMA IMAGEM PARA A CRIAÇÃO DE UMA GLCM  
FONTE: O autor (2015)

Devido à simetria, considera-se apenas os quatro valores para o ângulo: 0°, 45°, 90° e 135°. Observando a FIGURA 12, caso o valor da distância seja 1, e o valor do ângulo seja 0°, as combinações de brilho serão determinadas comparando o “Pixel Referência” ao “Pixel Vizinho 0” e ao “Pixel Vizinho 4”.

A contagem das diferentes combinações é feita percorrendo todos os pixels da imagem. Todas as possíveis combinações de níveis de cinza são contadas e formatadas em uma matriz, a GLCM.

Em uma imagem com 256 níveis de cinza, a GLCM referente a ela possui 256 linhas e 256 colunas, sendo que cada elemento  $M_{i,j}$  da matriz  $M$ , indica quantas ocorrências de pixels com nível de cinza  $i$  possuem um pixel vizinho com nível de cinza  $j$ .

Cada descritor de Haralick é calculado utilizando os valores da GLCM de uma forma diferente. Os descritores utilizados nos testes realizados neste trabalho foram: contraste, correlação, energia e homogeneidade.

O contraste é a medida da quantidade de variação local de níveis de cinza na imagem, descrito pela equação 3.

$$\text{Contraste} = \sum_i \sum_j (i - j)^2 P(i, j) \quad (3)$$

Onde  $P$  é o valor na posição  $i$  e  $j$  da GLCM.

A correlação representa uma ideia de linearidade de dependências de tons de cinza na imagem e é descrita pela equação 4.

$$\text{Correlação} = \frac{\sum_i \sum_j (i - \mu_i)(j - \mu_j)P(i, j)}{(\sigma_i \sigma_j)} \quad (4)$$

Onde  $P$  é o valor na posição  $i$  e  $j$  da GLCM,  $\mu$  representam as médias e  $\sigma$  representam os desvios padrão.

A energia retorna a soma dos elementos elevados ao quadrado dentro da GLCM, conforme a equação:

$$\text{Energia} = \sum_{i,j} P(i, j)^2 \quad (5)$$

onde  $P$  é o valor na posição  $i$  e  $j$  da GLCM.

A homogeneidade representa a proximidade da distribuição dos elementos em relação à diagonal da GLCM e é descrita pela equação:

$$\text{Homogeneidade} = \sum_{i,j} \frac{P(i, j)}{1 + |i - j|} \quad (6)$$

onde  $P$  é o valor na posição  $i$  e  $j$  da GLCM.

### 2.2.7 Local Phase Quantization

O *Local Phase Quantization* (LPQ) é um descritor de textura robusto a desfocagem da imagem, proposto originalmente por Ojansivu e Heikkilä (2008). Este descritor apresenta um excelente desempenho em análise de textura de imagens. Sua principal característica é a robustez para imagens borradas ou afetadas por iluminação não uniforme.

A proposta deste descritor é que, a partir de cada pixel  $x$  de uma imagem  $N$ , seja possível representar a textura dos pixels, considerando uma vizinhança regular  $V_x (m \times m)$ . A FIGURA 13 apresenta o procedimento simplificado para o cálculo da LPQ, que neste exemplo, é calculada a LPQ 5x5 para um pixel.




FIGURA 13 – PROCEDIMENTO SIMPLIFICADO PARA O CÁLCULO DA LPQ  
 FONTE: Adaptado de Department of Computer Science and Engineering (2011)

Primeiramente, a transformada de Fourier de curto termo (STFT) é calculada por meio de uma janela quadrada  $N_x$  para cada pixel  $x$  da imagem, em cada domínio da frequência  $u$ . Esta função é definida pela equação 7.

$$F(u, x) = \sum_{y \in N_x} f(x - y) e^{-j2\pi u^T y} \quad (7)$$

Os coeficientes de Fourier locais são calculados para os quatro pontos do domínio da frequência:  $u_1 = [a, 0]^T$ ,  $u_2 = [0, a]^T$ ,  $u_3 = [a, a]^T$  e  $u_4 = [a, -a]^T$ , resultando, para cada posição de pixel, o vetor:

$$F_x = [F(u_1, x), F(u_2, x), F(u_3, x), F(u_4, x)] \quad (8)$$



Em seguida, a informação de fase nos coeficientes de Fourier é registrada por meio da observação dos sinais das partes real  $Re(w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4})$  e imaginária  $Im(w_{u_1}, w_{u_2}, w_{u_3}, w_{u_4})$  de cada componente em  $F_x$ , onde  $w_u$  é um vetor contendo os exponenciais complexos na frequência  $u$ . Isto é feito utilizando um quantizador escalar simples:

$$q_j(x) = \begin{cases} 1, & \text{se } g_j(x) \geq 0 \\ 0, & \text{caso contrário} \end{cases}, \quad (9)$$

onde  $g_j(x)$  é o  $j$ -ésimo componente do vetor  $G_x = [Re\{F_x\}, Im\{F_x\}]$ .

Os oito coeficientes binários resultantes  $q_j(x)$  são representados como valores inteiros entre 0 e 255 utilizando codificação binária. Esses valores são contabilizados e, por fim, é gerado um histograma desses valores inteiros de todos os pixels e utilizado como um vetor de 256 características.

Como exemplos de utilização do descritor, pode-se verificar o trabalho de Lei e Li (2012), que aplicaram o LPQ para a realização de reconhecimento facial, e conseguiram um resultado de 98% em um dos testes efetuados. Já a pesquisa de Nanni et al. (2012) utilizou o LPQ para distinguir tecidos em mamografias como benignos ou malignos, obtendo uma taxa de acerto de 95% na melhor de suas análises.

### 2.3 REDES BAYESIANAS

Segundo Russell e Norvig (2009), redes Bayesianas (RB) são grafos acíclicos, dirigidos, que representam dependências entre variáveis representadas por nós, podendo atribuir valores conforme o grau de relevância em um modelo probabilístico. Esta abordagem representa uma boa estratégia para lidar com problemas que tratam com incertezas, onde conclusões não podem ser construídas apenas com base no conhecimento prévio a respeito do problema.

Uma rede Bayesiana é constituída de um modelo gráfico, constituído por nós e arcos que representam respectivamente as variáveis do universo estudado e as dependências entre estas. A direção dos arcos representa a relação de causa e efeito entre as variáveis. Na associação entre as variáveis, existe uma representação de probabilidades, onde são definidas as probabilidades condicionais de cada nó em relação aos seus pais, explica Saheki (2005).

As redes Bayesianas são um modelo de representação do conhecimento que trabalha com o conhecimento incerto e incompleto através da teoria da probabilidade (RICH E KNIGHT, 1991).

A principal vantagem de usar o raciocínio probabilístico sobre raciocínio lógico é que os agentes podem tomar decisões racionais mesmo quando exista pouca informação para provar alguma ação (CHARNIAK, 1991).

As redes Bayesianas são capazes de representar incerteza no conhecimento, utilizando o teorema de Bayes (TB), onde se pode coletar os dados necessários para o modelo do domínio por meio de estudos estatísticos publicados, consulta a especialistas ou através de características extraídas de uma base de dados (KOEHLER, 2002).

O teorema de Bayes apresenta uma abordagem para calcular probabilidades, dado um conjunto de informações pré-existentes. A probabilidade mede a frequência na qual um evento ocorre numa população e reflete a crença de que aquele evento se repetirá em um indivíduo (PEARL, 2000).

O teorema de Bayes permite que as probabilidades desconhecidas sejam calculadas a partir de probabilidades condicionais conhecidas (REZENDE, 2003).

Bayes desenvolveu a teoria básica da probabilidade condicional, que é baseada na existência de evidências, ou seja, a probabilidade de alguma coisa acontecer, considerando a evidência de que outra coisa já ocorreu (LEVINE et al., 1988).

Após a aquisição de informações, obtidas através de características extraídas de uma imagem digital, por exemplo, pode-se calcular a probabilidade do elemento na imagem ser um determinado tipo de alimento, com o auxílio do teorema de Bayes, descrito na equação 10.

$$P(H_i | e) = \frac{P(e | H_i) \cdot P(H_i)}{\sum_{j=1}^k (P(H_j) \cdot P(e | H_j))} \quad (10)$$

Onde:

$P(H_i | e)$ : probabilidade que a hipótese  $H_i$  seja verdadeira dada a evidência  $e$ ;

$P(e | H_i)$ : probabilidade que a evidência  $e$  seja verdadeira se a hipótese  $H_i$  for verdadeira;

$P(H_i)$ : probabilidade que a hipótese  $H_i$  seja verdadeira na ausência de qualquer evidência específica;

$k$ : número de hipóteses possíveis.

Conforme Tu et al. (1993), uma Rede Bayesiana é composta de duas partes complementares: a parte qualitativa e a parte quantitativa. A parte qualitativa expressa a relação causal entre os nós e a parte quantitativa determina a força desta relação, através da probabilidade condicional.

### 2.3.1 Parte Qualitativa

As redes Bayesianas oferecem uma representação flexível que permite especificar dependências e independências das variáveis de uma forma simples. As dependências são expressas qualitativamente, como ligações entre nós, e podem estruturar o domínio do conhecimento qualitativamente antes que qualquer probabilidade numérica seja determinada e inserida (KOEHLER, 2002).

A parte qualitativa da rede Bayesiana é apresentada por um modelo gráfico, sendo as variáveis representadas por nós e as relações entre elas representadas por arcos direcionados. Assim, um arco ligando as variáveis  $A \rightarrow B$ , indica que a variável  $B$  é a consequência e a variável  $A$  é a causa, e essas apresentam uma relação de dependência, resumidas na regra “se  $A$  então  $B$ ” (DIAS, 2004). Um modelo gráfico da parte qualitativa é apresentado na FIGURA 14.




FIGURA 14 – EXEMPLO DA PARTE QUALITATIVA DE UMA REDE BAYESIANA  
FONTE: O autor (2015)

Conforme mostra a FIGURA 14, supondo que sejam utilizados apenas as médias *red*, *green* e *blue* como características para classificar o alimento em um prato, um exemplo seria afirmar que um prato com qualquer alimento (variável *A*) é a causa da média de cores do plano vermelho da imagem (variável *B*) ter um determinado valor. Isto é, os valores das características de um alimento (variáveis *B*, *C* e *D*), são a consequência de se ter analisado este determinado prato de alimento (variável *A*).

### 2.3.2 Parte Quantitativa

A parte quantitativa da rede Bayesiana é o conjunto de probabilidades condicionais associadas a cada arco criado no modelo gráfico e às probabilidades das hipóteses estimadas inicialmente. Após definida a topologia da RB, basta especificar as probabilidades condicionais para os nós que possuem dependências diretas e as utilizar para computar qualquer outro valor de probabilidade (GAAG, 1996). Um exemplo gráfico da parte quantitativa é apresentado na FIGURA 15.

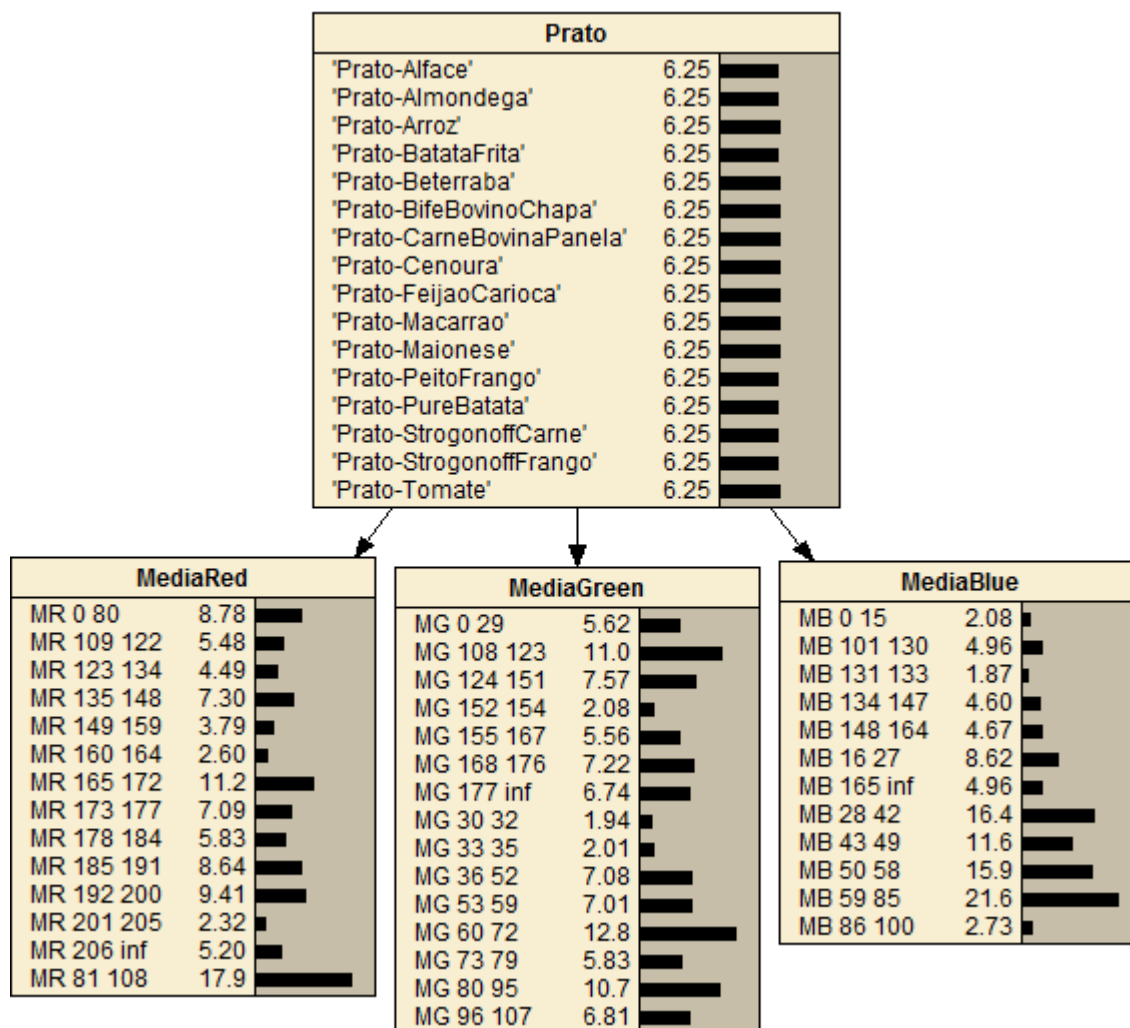


FIGURA 15 – EXEMPLO DA PARTE QUANTITATIVA DE UMA REDE BAYESIANA  
FONTE: O autor (2015)

Conforme é possível observar na FIGURA 15, cada um dos 16 tipos de alimentos (nó Prato) possui a mesma chance de ser classificado pela rede, isto é, 6,25%. Cada linha nos nós MediaRed, MediaGreen e MediaBlue são faixas de valores, obtidas a partir da clusterização das características, considerando que os valores das características são números inteiros que variam entre 0 e 255. Com isso, ainda na FIGURA 15, na primeira linha do nó MediaRed, pode-se afirmar que um alimento qualquer possui a probabilidade de 8,78% de apresentar um valor entre 0 e 80 de média de cores do plano vermelho. Já na FIGURA 16, observa-se que, caso o valor da média de cores do plano vermelho (nó MediaRed) seja um valor entre 0 e 80, as probabilidades dos outros nós sofrem alteração, afirmando que o alimento em questão possui chances de 60,8% de ser beterraba e 28,0% de ser almondegas.

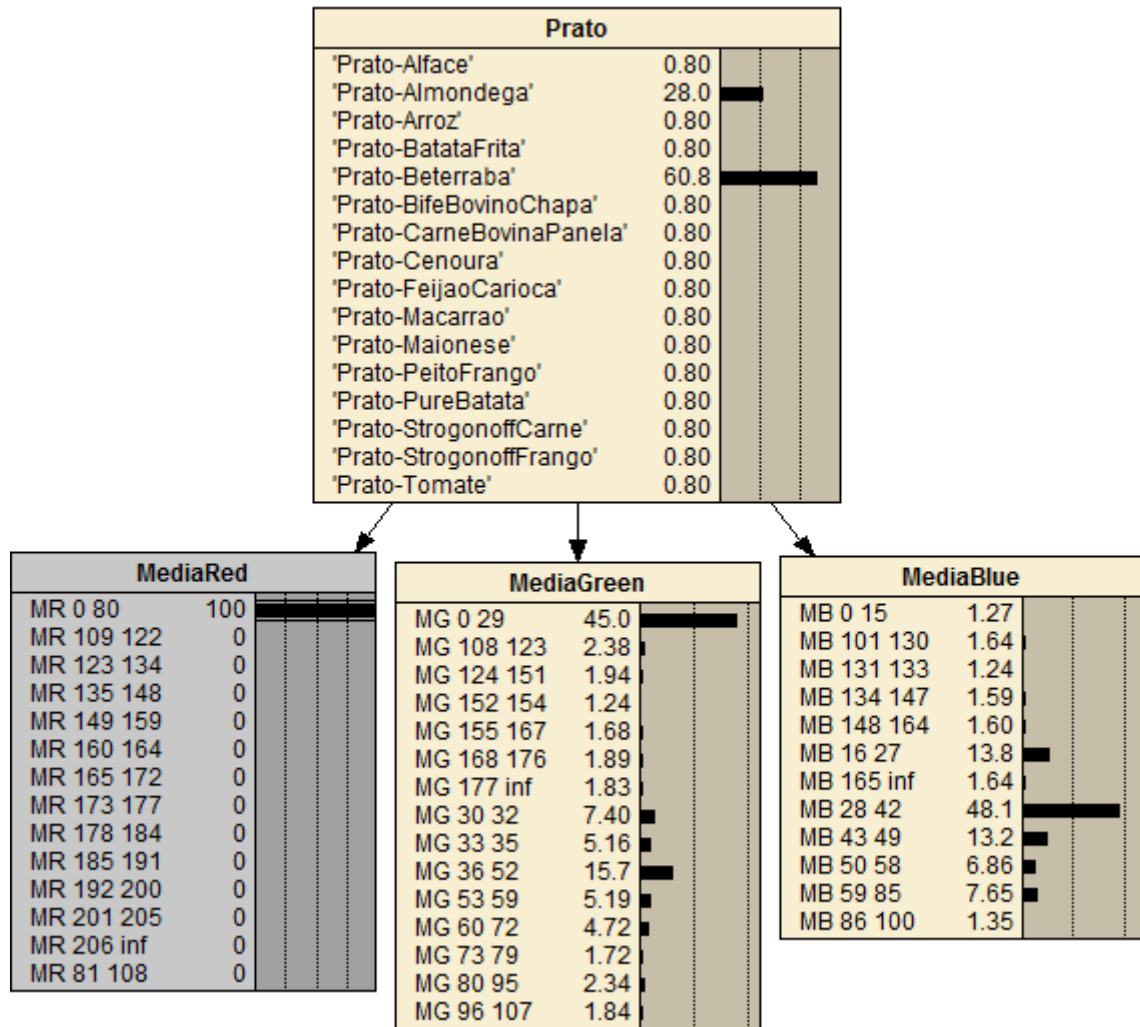


FIGURA 16 – EXEMPLO DA PARTE QUANTITATIVA DE UMA REDE BAYESIANA CONSIDERANDO QUE O VALOR DA MÉDIA RED POSSUI UM VALOR ENTRE 0 E 80  
 FONTE: O autor (2015)

As Redes Bayesianas podem ser treinadas diretamente a partir de características extraídas de uma base de dados, criadas por especialistas ou desenvolvidas em combinação com estas duas técnicas. Elas capturam conhecimento de maneira modular e este conhecimento pode ser transportado de uma situação para outra, de maneira que o usuário possa visualizar claramente os relacionamentos envolvidos. A aprendizagem da RB descobre os relacionamentos entre as variáveis e a força desses relacionamentos (BERNER, 1999).

### 2.3.3 Clusterização

A clusterização tem como objetivo separar os registros da base de dados em classes (clusters). Aplicável em situações em que os registros de dados não estejam

enquadrados em classes predefinidas, esta tarefa consistem em agrupar os dados em função de sua similaridade (GOLDSCHMIDT E PASSOS, 2005).

Para isso, utiliza-se um algoritmo de clusterização de dados. Em geral, esses algoritmos incluem um novo atributo no conjunto de dados original, de forma que este novo atributo indique a qual cluster cada registro pertence.

Então, cada rótulo de cluster passa a ser considerado como uma classe. Com isso, os algoritmos de classificação podem ser aplicados de forma a gerar modelos de conhecimento que possam prever a classificação de novos registros a partir das características dos dados (GOLDSCHMIDT E PASSOS, 2005).

Neste trabalho, o algoritmo de clusterização utilizado foi o K2, apresentado por Cooper e Herskovits (1992). O algoritmo K2 avalia as possíveis topologias de uma rede Bayesiana calculando a probabilidade dessa topologia gerar a base de dados em questão. O K2 usa uma abordagem por modelo de seleção, onde uma métrica de pontuação guia um algoritmo simples na busca pela melhor rede.

O K2 procura dentre as  $2^{n(n-1)/2}$  configurações possíveis, sendo  $n$  o número de variáveis, a configuração que maximiza a função de pontuação e permite encontrar a mais provável estrutura de rede de crença  $B_S$ , a partir de um determinado conjunto de dados  $D$  (HECKERMAN, 1997). O algoritmo K2 aplica a pontuação Bayesiana segundo a equação 11.

$$P(B_S | D) = \prod_{i=1}^n \prod_{j=1}^{q_i} \frac{\Gamma(r_i)}{\Gamma(r_i + N_{ij})} \prod_{k=1}^{r_i} \Gamma(N_{ijk} + 1) \quad (11)$$

Onde:

- $B_S \rightarrow$  atributo (causa);
- $D \rightarrow$  conjunto de dados (consequência);
- $i \rightarrow$  variável estudada;
- $j \rightarrow$  variável de correlação;
- $k \rightarrow$  estados dos atributos que serão pontuados na rede Bayesiana;
- $n \rightarrow$  número de nós;
- $q_i \rightarrow$  número de configurações dos pais da variável  $X_i$ ;
- $r_i \rightarrow$  número de possíveis valores do nó  $X_i$ ;

- $N_{ijk} \rightarrow$  número de casos em  $D$  onde o atributo  $X_i$  é instanciado com seu valor  $k$ , e a configuração dos pais de  $X_i$  é instanciada com o valor  $j$ ;
- $N_{ij} \rightarrow$  número de observações em que a configuração dos pais de  $X_i$  é instanciada com o valor  $j$ , sendo  $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$ .

A partir do uso deste método, pode-se gerar uma RB para cada conjunto de dados e aplicar o algoritmo de propagação para efetuar inferências sobre essa rede.

O processo de aprendizagem da estrutura de uma RB pode demandar grande quantidade de cálculos matemáticos, dependendo do número de variáveis envolvidas na rede. Parte do seu funcionamento consiste na busca pelas frequências das correlações entre os estados dos atributos do domínio, que é representado pelo  $N_{ij}$  e  $N_{ijk}$  (HECKERMAN, 1997).

Esse mecanismo percorre todas as combinações dos registros dos atributos na base de dados, a fim de obter as frequências correspondentes de cada relação para cada estado de cada atributo da rede Bayesiana (HECKERMAN, 1997).

## 2.4 FUSÃO DE INFORMAÇÕES

A fusão de informações utiliza diferentes técnicas para trabalhar com dados provenientes de múltiplas fontes, ou múltiplos dados extraídos de uma única fonte (XIAO, 2007). Seu objetivo é obter o melhor entendimento de algum fenômeno para introduzir inteligência e funções de decisão.

A fusão possui quatro níveis: fusão em nível de amostra, fusão em nível de primitiva, fusão em nível de pontuação e fusão em nível de decisão.

### 2.4.1 Fusão em Nível de Amostra

A fusão em nível de amostra ocorre quando a fusão é realizada logo após a aquisição das informações, conforme mostra a FIGURA 17.



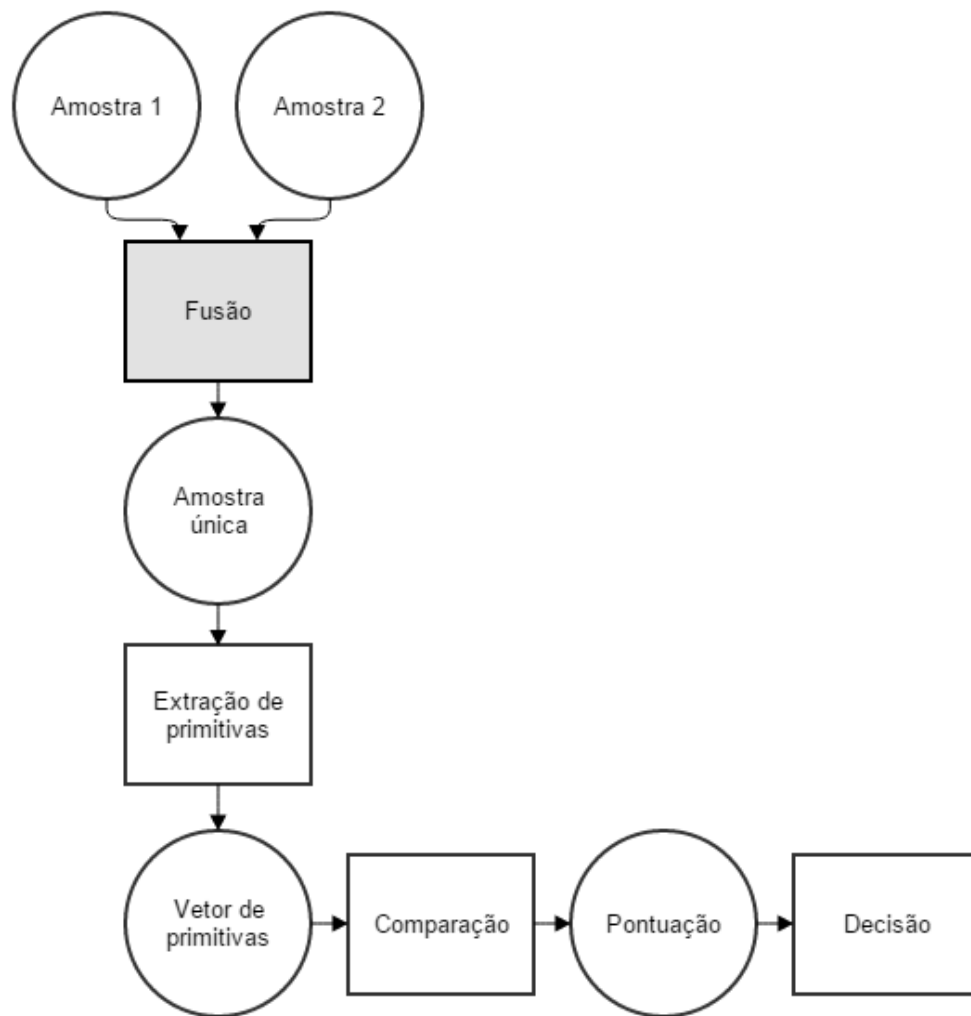


FIGURA 17 – FUSÃO EM NÍVEL DE AMOSTRA  
 FONTE: Adaptado de Yano (2011)

Na fusão em nível de amostra, os dados brutos capturados podem ser concatenados ou combinados por operações como soma e subtração, ou através de algoritmos estáticos, como média e mediana. Esse tipo de fusão é mais comum em sistemas multiapresentação, para obtenção de uma única amostra de melhor qualidade (HICKLIN et al., 2006).

Em sistemas multimodais, a amostra combinada deve trazer informações de todas as características capturadas. No entanto, esse tipo de fusão não é muito utilizado, por não apresentar vantagens sobre a fusão em outros níveis, além de muitas vezes não ser possível devido à incompatibilidade de formato dos dados adquiridos de diferentes sensores (HICKLIN et al., 2006).

### 2.4.2 Fusão em Nível de Primitiva

O segundo nível em que pode ocorrer a fusão em um sistema, é logo após a extração de primitivas. A FIGURA 18 apresenta esse caso, no qual diferentes amostras têm suas características extraídas, resultando em dois ou mais vetores de primitivas. Esses vetores são combinados em um único vetor de primitivas que será utilizado para a comparação no sistema (HICKLIN et al., 2006).

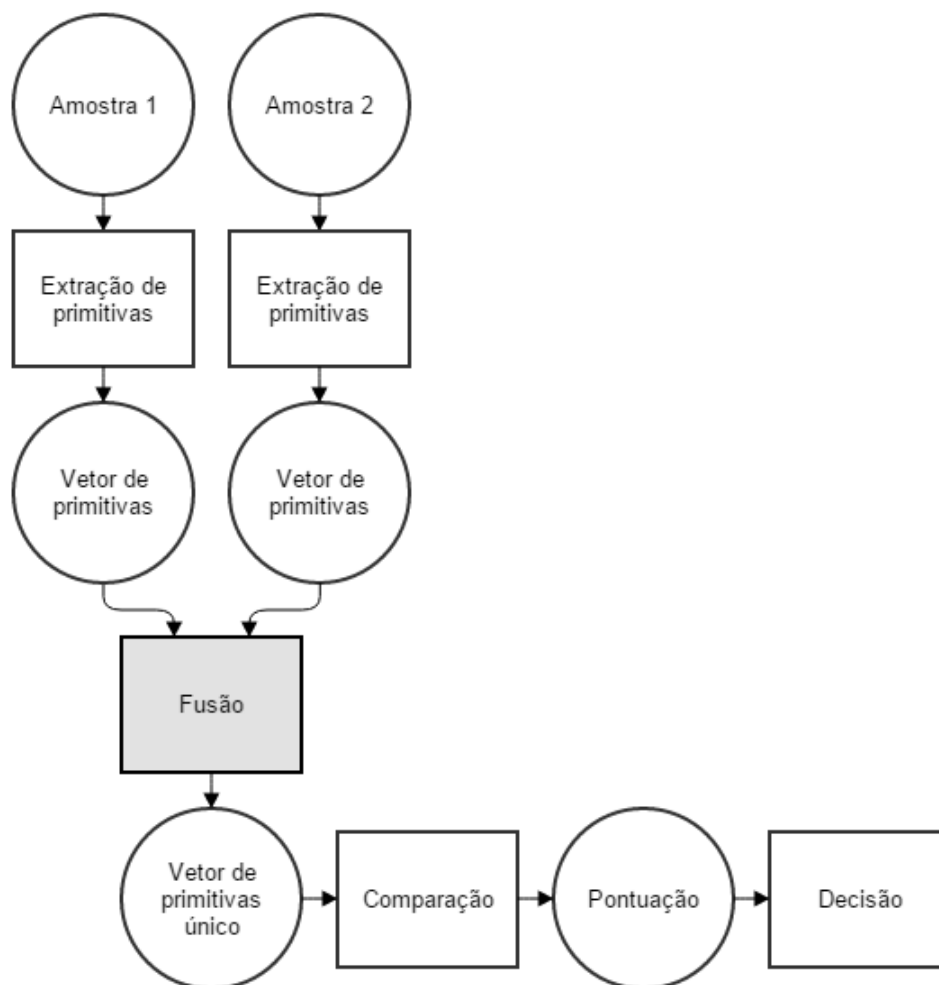


FIGURA 18 – FUSÃO EM NÍVEL DE PRIMITIVA  
FONTE: Adaptado de Yano (2011)

A fusão em nível de primitiva, também chamada de fusão de características, é uma técnica utilizada para trabalhar com dados provenientes de múltiplas fontes, ou múltiplos dados extraídos de uma única fonte, conforme Xiao (2007).

Na fusão de características, diferentes conjuntos de características são combinados, resultando em um único vetor de características, conforme Maltoni et al. (2009). Essa combinação pode ser realizada com concatenação simples, operações como soma e subtração ou através de algoritmos estáticos, como média e mediana.

Neste trabalho, a técnica de fusão utilizada foi a fusão de características, ou fusão em nível de primitiva. A FIGURA 19 exemplifica a utilização dessa técnica neste trabalho.

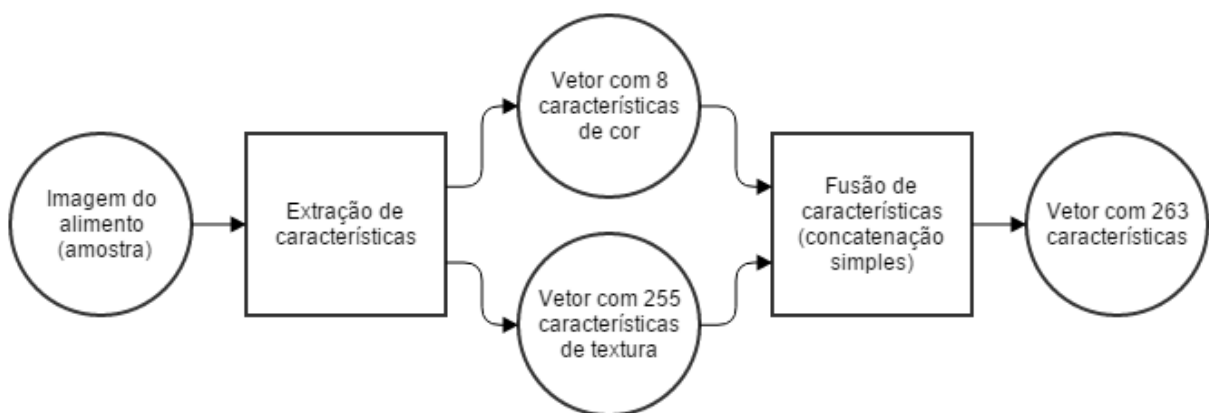


FIGURA 19 – EXEMPLIFICAÇÃO DA TÉCNICA DE FUSÃO DE CARACTERÍSTICAS  
FONTE: O autor (2015)

Essa técnica foi executada utilizando concatenação simples, ou seja, o vetor com 8 características de cor e o vetor com 255 características de textura foram concatenados, resultando um único vetor com 263 características.

Não há a necessidade de atribuir peso e nem de realizar a normalização das características utilizadas neste trabalho, pois a rede Bayesiana fará automaticamente uma ponderação pelas probabilidades condicionais capturadas do conjunto de dados de treinamento da rede.

#### 2.4.3 Fusão em Nível de Pontuação

Na fusão em nível de pontuação, cada amostra é tratada de forma independente até a etapa de comparação, resultando em uma pontuação de correspondência para cada caso, conforme mostra a FIGURA 20.

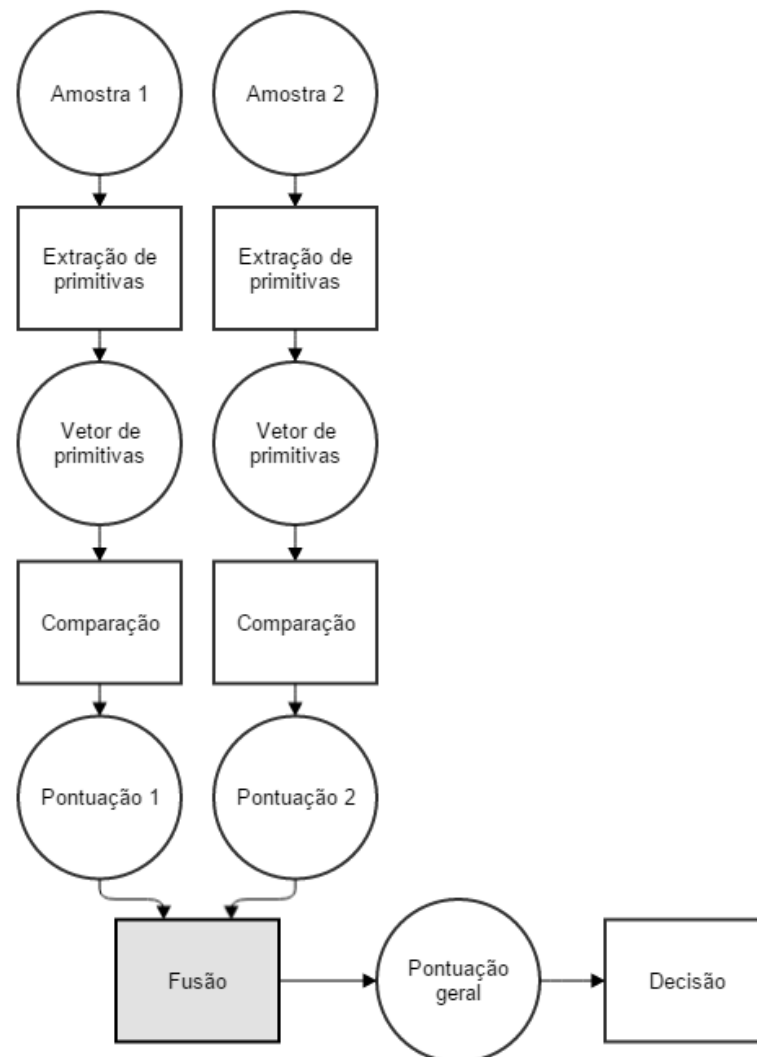


FIGURA 20 – FUSÃO EM NÍVEL DE PONTUAÇÃO  
 FONTE: Adaptado de Yano (2011)

A fusão em nível de pontuação pode ser realizada através de diferentes métodos: pontuação máxima, pontuação mínima, soma ponderada, produto ponderado, árvore de decisão, análise discriminante linear e redes neurais. Porém é essencial que antes da fusão, seja feita uma normalização dos valores obtidos (HICKLIN et al., 2006).

#### 2.4.4 Fusão em Nível de Decisão

Na fusão em nível de decisão, cada teste é efetuado de forma independente para realizar a classificação, e posteriormente, cada decisão tomada será ponderada para tomar uma decisão final (GIGLI et al., 2007). A FIGURA 21 apresenta esse caso.

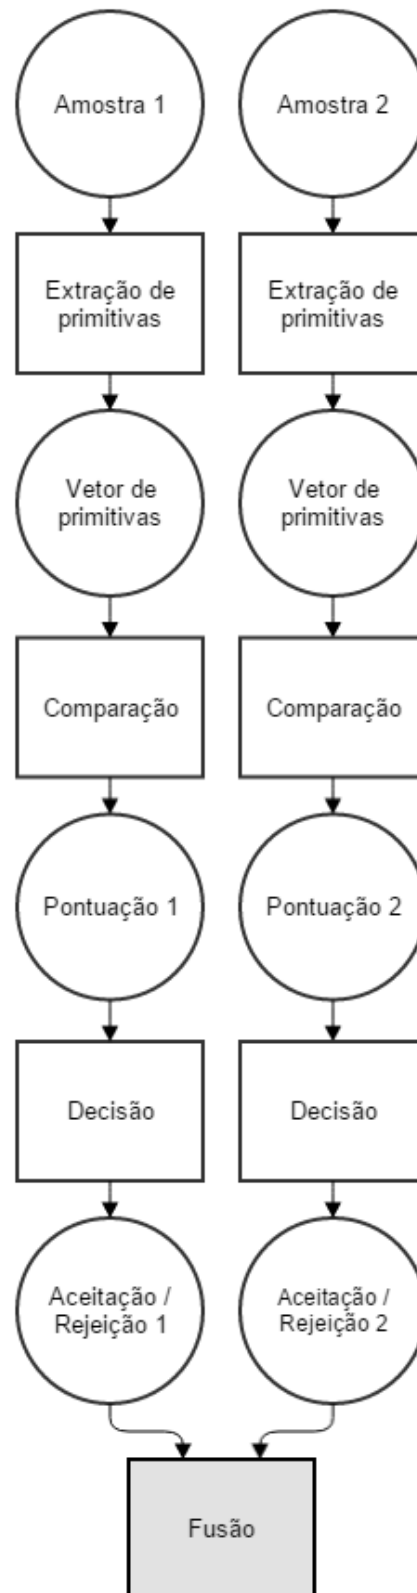


FIGURA 21 – FUSÃO EM NÍVEL DE DECISÃO  
FONTE: Adaptado de Yano (2011)

Para a fusão em nível de decisão, geralmente é utilizada a decisão por voto majoritário, na qual a decisão de cada subsistema corresponde a um voto e o

resultado final corresponde ao dado pela maioria (KUNCHEVA, 2004). Nesse caso, é preferível usar um número ímpar de classificadores, para evitar um possível empate de resultados.

## 2.5 TÉCNICAS DE AVALIAÇÃO

Existem várias técnicas para determinar o desempenho de classificadores. Esse desempenho é medido pela precisão, ou seja, simplesmente contando a quantidade de amostras classificadas corretamente em um conjunto de dados (BOUCKAERT et al., 2010). A seguir serão mostradas as técnicas de avaliação utilizadas para determinar o desempenho da rede Bayesiana deste trabalho.

### 2.5.1 Validação Cruzada (*Cross-Validation*)

A validação cruzada é uma técnica baseada na avaliação dos erros de previsão, comparando os valores das variáveis dependentes das amostras do conjunto de calibração com as respectivas previsões, quando as mesmas não participam da construção do modelo de regressão (SIMAS, 2005). Giordanengo (2005) sugere que a validação cruzada seja utilizada nos casos em que o número de amostras é limitado.

Na validação cruzada, as amostras para validação são as mesmas usadas no teste de calibração. Uma parte das amostras é separada, então o treinamento é realizado com as amostras restantes e os testes são feitos utilizando as amostras separadas inicialmente. O procedimento é realizado para cada amostra ou subconjunto de amostras até que todo o conjunto de dados iniciais seja explorado (SOTELO, 2006).

O método de validação cruzada utilizado neste trabalho foi o *k-fold*, onde, primeiramente, os dados são ordenados de forma aleatória, em seguida, o conjunto de dados é dividido em  $k$  subconjuntos de tamanhos iguais. Um subconjunto, dos  $k$  subconjuntos, é utilizado para testar o sistema treinado com os demais  $k-1$  subconjuntos. Esse processo irá se repetir por  $k$  vezes. (LIANG E DAVIER, 2014). A FIGURA 22 apresenta um exemplo da técnica de validação cruzada utilizando *k-fold*, sendo  $k = 10$ .




FIGURA 22 – EXEMPLO DA TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO O MÉTODO *K-FOLD*

FONTE: Adaptado de McCormick (2013)

Conforme é possível observar na FIGURA 22, o conjunto de dados possui um total de 1200 amostras. Esse conjunto é dividido em 10 partes iguais, em seguida, percorre-se 10 vezes esse conjunto de dados, utilizando 9 partes para treinamento e 1 parte para validação (teste). Cada interação resulta uma porcentagem de acerto, e o resultado final obtido se dá a partir da média dos resultados de cada interação.

### 2.5.2 Conjunto de Teste Fornecido (*Supplied Test Set*)

Conjunto de teste fornecido é uma técnica utilizada para avaliar testes de classificação. Para essa técnica, devem-se possuir dois conjuntos distintos de dados, onde um será utilizado para o treinamento da rede e o outro para o teste da rede (BOUCKAERT et al., 2010).

### 2.5.3 Matriz de Confusão

A matriz de confusão, também conhecida como matriz de erro, é utilizada para avaliar o resultado de uma classificação, a fim de verificar a qualidade dos dados contidos nesse mapa. A confiabilidade da matriz de confusão depende da amostragem, registro e conhecimento (CONGALTON E GREEN, 1999).

A matriz de confusão é formada por um arranjo quadrado de números dispostos em linhas e colunas que expressam o número de unidades de amostras de uma categoria particular relativa, inferida por um classificador, comparado com a categoria atual verificada no campo (CONGALTON, 1991).

Normalmente, ao longo das colunas se representa o conjunto de dados de referência, que é comparado com os dados do resultado da classificação, representados ao longo das linhas.

Na matriz de confusão, os elementos da diagonal principal indicam o nível de acerto entre os conjuntos de dados. Já os elementos fora da diagonal principal indicam as amostras classificadas incorretamente. A FIGURA 23 apresenta a representação de uma matriz de confusão.

a	b	c	d	e	<-- classificação
10	0	0	0	0	a = Conjunto 1
0	9	0	0	1	b = Conjunto 2
0	0	10	0	0	c = Conjunto 3
3	2	0	5	0	d = Conjunto 4
0	1	1	1	7	e = Conjunto 5

FIGURA 23 – EXEMPLO DE UMA MATRIZ DE CONFUSÃO  
FONTE: O autor (2015)

Conforme é possível observar na FIGURA 23, para uma melhor visualização da matriz, cada conjunto de dados é rotulado com uma letra, por exemplo, o “Conjunto 1” é rotulado com a letra “a”. Na matriz de exemplo apresentada, o “Conjunto 1” e o “Conjunto 3” tiveram uma taxa de acerto de 100%, pois observando as linhas correspondentes à estes conjuntos, é possível verificar que os valores fora da diagonal principal estão zerados. Observando a linha correspondente ao “Conjunto 4”, verifica-se que de um total de 10 amostras testadas, 5 foram classificadas corretamente, pois estão na diagonal principal (linha “d” e coluna “d”), 3 foram classificadas como “Conjunto 1” e 2 foram classificadas como “Conjunto 2”.

#### 2.5.4 Curva ROC

A curva *Receiver Operating Characteristic* (ROC) é uma forma de representar a relação entre a sensibilidade, ou *true positive rate* (TPR), e a especificidade, ou *true negative rate* (TNR), de um teste quantitativo ao longo de



valores contínuos de ponto de corte. Para se construir uma curva ROC, traça-se um diagrama que represente a sensibilidade em função da proporção de falsos positivos, ou *false positive rate* (FPR), para um conjunto de valores de ponto de corte (MASSAD et al.,2004).

A sensibilidade (TPR) é definida como a probabilidade do teste sob investigação fornecer um resultado positivo. Já a especificidade (TNR) é definida como a probabilidade do teste fornecer um resultado negativo (MARTINEZ et al., 2003).

As fórmulas para os cálculos da TPR, TNR e FPR são apresentadas nas equações 12, 13 e 14 respectivamente.

$$TPR = S = \frac{VP}{VP + FN} \quad (12)$$

$$TNR = E = \frac{VN}{VN + FP} \quad (13)$$

$$FPR = 1 - E = \frac{FP}{FP + VN} \quad (14)$$

Onde:

- $S$  é a sensibilidade;
- $E$  é a especificidade;
- $VP$  são verdadeiros positivos;
- $FP$  são falsos positivos;
- $VN$  são verdadeiros negativos;
- $FN$  são falsos negativos.

Por exemplo, em um teste com um total de 240 amostras, de 15 amostras de uma classe qualquer, 13 foram classificadas corretamente e 2 foram classificadas incorretamente, além disso, 8 amostras que não fazem parte dessa classe foram classificadas incorretamente como se fossem parte dessa classe. Então, os valores base para o cálculo da sensibilidade e da especificidade são:

- $VP = 13$ ;
- $FP = 217$ ;
- $VN = 8$ ;
- $FN = 2$ .

Aplicando os valores do exemplo nos cálculos da TPR, TNR e FPR, os resultados obtidos são:

- $TPR = S = 0,867$ ;
- $TNR = E = 0,036$ ;
- $FPR = 1 - E = 0,964$ .

A curva ROC descreve a capacidade discriminativa de um teste para um determinado número de valores de ponto de corte. Isso permite colocar em evidência os valores para os quais existe uma maior otimização da sensibilidade em função da especificidade. O ponto na curva ROC em que isso acontece é aquele que se encontra mais próximo do canto superior esquerdo do diagrama (SILVA, 2004).

Uma medida que resume o desempenho de um teste é a área sob a curva ROC, que é estimada considerando todas as sensibilidades e especificidades relativas a cada ponto de corte estipulado. Uma área igual a 1 representa um teste perfeito, já uma área igual a 0,5 representa um teste no qual os acertos e erros entraram na mesma proporção. Logo, quanto maior a área sob a curva ROC, melhor é a classificação de um teste conforme seu desempenho (MARTINEZ et al., 2003).

## 2.6 Trabalho Relacionado

Uma proposta semelhante à deste trabalho é o DietCam, um sistema desenvolvido para iPhone® por Kong e Tan (2012), com a capacidade de reconhecer alguns alimentos a partir de imagens obtidas através de uma câmera de celular e fornecer ao usuário o valor calórico dos alimentos da imagem.

As características utilizadas no DietCam para reconhecer e classificar os alimentos são vetores obtidos através da *Scale Invariant Feature Transform* (SIFT), um método desenvolvido por Lowe (1999) para detectar pontos característicos em

imagens invariantes, que podem ser combinados entre as imagens para executar tarefas como detecção e reconhecimento de objetos.

No DietCam, as características SIFT das imagens obtidas são extraídas e comparadas com características SIFT armazenadas em uma base de dados, utilizando cálculos baseados no teorema de Bayes. Então, modelos tridimensionais são criados para detectar e classificar os alimentos nas imagens, e utilizados para estimar o volume desses alimentos e calcular seu valor calórico.

O subcapítulo 4.4 apresenta algumas comparações entre o sistema apresentado neste trabalho e o DietCam.

### 3 MATERIAL E MÉTODOS

Este capítulo apresenta os materiais e métodos utilizados neste trabalho. Primeiramente, no subcapítulo 3.1, é apresentada uma visão geral do sistema proposto neste trabalho, seguido de seu diagrama de blocos. Em seguida, no subcapítulo 3.2, é mostrado o método para a aquisição da base de dados utilizada. No subcapítulo 3.3, são explicadas as técnicas utilizadas para pré-processar as imagens. O subcapítulo 3.4 apresenta as técnicas utilizadas para executar a segmentação dos alimentos da imagem. No subcapítulo 3.5, o método de extração de características é explicado. Por último, o subcapítulo 3.6 apresenta o método utilizado para realizar a classificação dos alimentos.

#### 3.1 VISÃO GERAL

O sistema apresentado neste trabalho necessita que os alimentos estejam devidamente separados no prato, pois o sistema ainda não possui a capacidade de detectar a sobreposição e/ou a mistura dos alimentos. As suas principais etapas são: pré-processamento da imagem, segmentação, extração de características e classificação do alimento.

Desenvolvido em MATLAB®, o sistema possui como parâmetro de entrada a imagem do prato com as porções alimentares. Já a saída do sistema é a classificação de cada alimento segmentado. A FIGURA 24 apresenta o fluxograma da entrada, estrutura e saída do sistema.

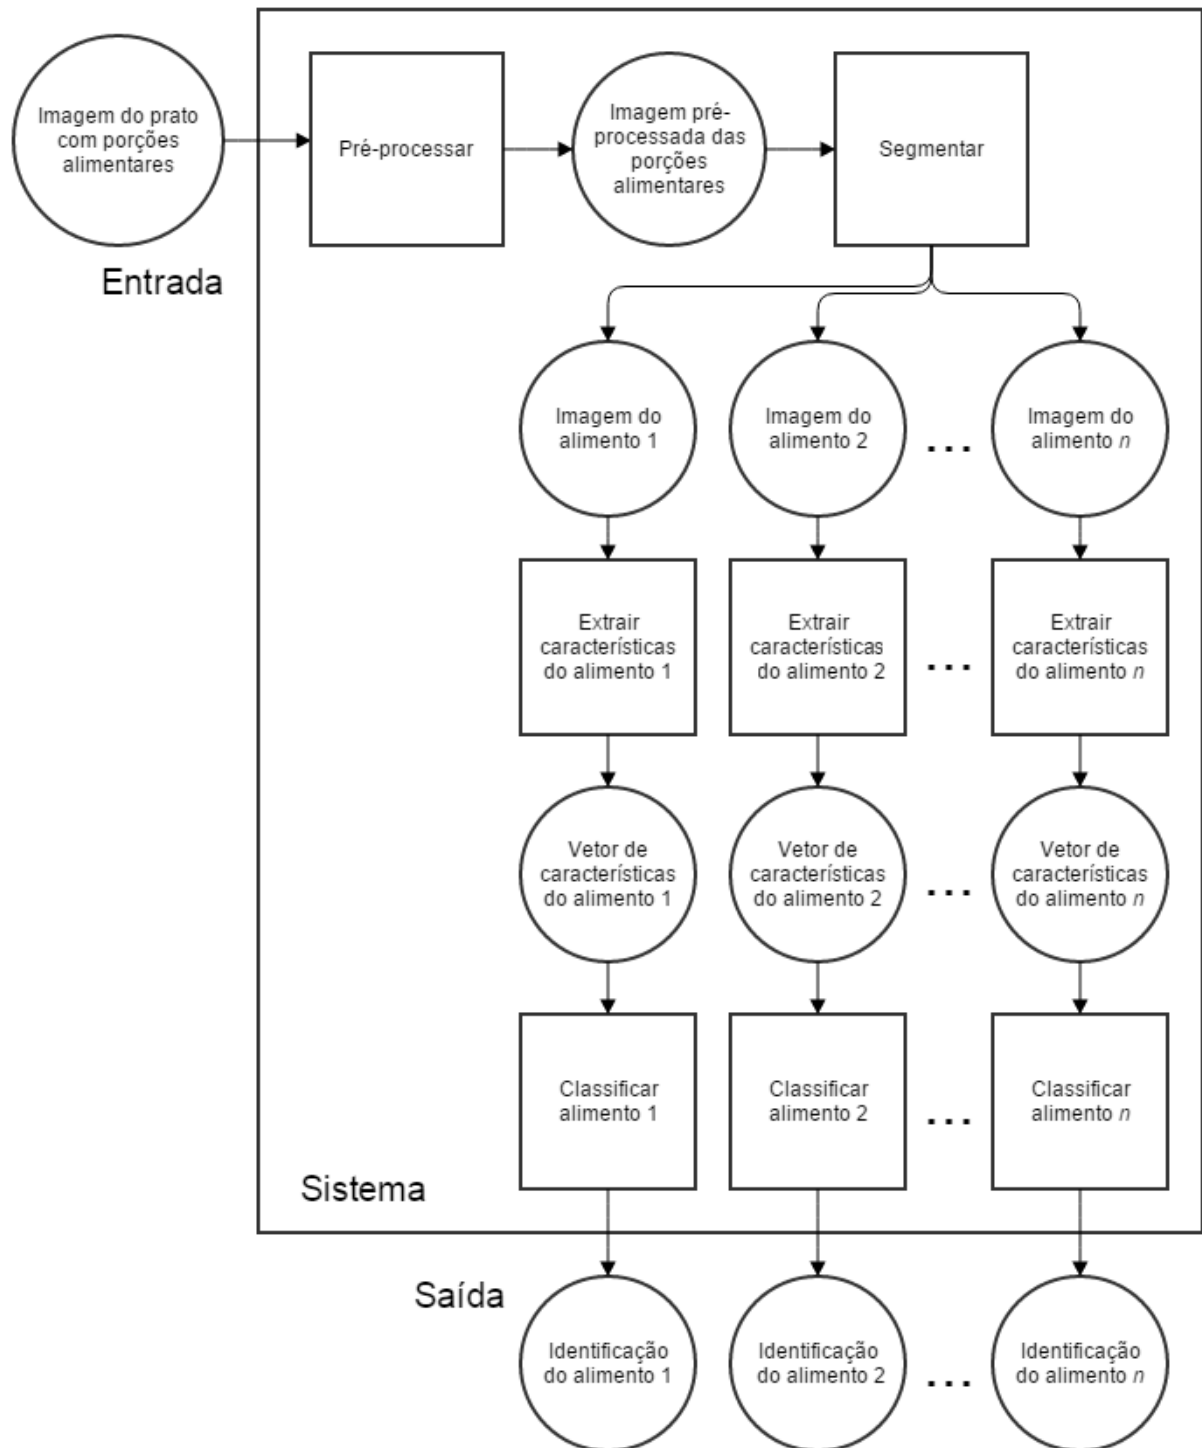


FIGURA 24 – FLUXOGRAMA DA ENTRADA, ESTRUTURA E SAÍDA DO SISTEMA PROPOSTO  
FONTE: O autor (2015)

Para que o sistema pudesse ser implementado e testado, foi necessário criar uma base de imagens, apresentada no capítulo 3.2.

### 3.2 BASE DE DADOS

Para o desenvolvimento deste trabalho, foram adquiridas imagens de dezesseis alimentos. Esses alimentos são:

- alface;
- almôndega;
- arroz branco;
- batata frita;
- beterraba;
- bife bovino na chapa;
- carne bovina de panela;
- cenoura;
- feijão carioca;
- macarrão;
- maionese;
- peito de frango à milanesa;
- purê de batatas;
- estrogonofe de carne;
- estrogonofe de frango;
- tomate.

Todas as imagens foram adquiridas no mesmo ambiente, com uma câmera de 5 megapixels de um smartphone Motorola® Moto G XT1033 com a função de flash ativada. A FIGURA 25 apresenta a maneira como as imagens foram obtidas, posicionando a câmera sobre o prato em um ângulo de 90°, a uma distância aproximada de 45 cm.




FIGURA 25 – POSICIONAMENTO DA CÂMERA PARA A AQUISIÇÃO DAS IMAGENS OBTIDAS  
FONTE: O autor (2015)

Os alimentos foram posicionados em um prato de 27 cm de diâmetro, cor branca e formato circular. Apesar das imagens terem sido obtidas em dias diferentes, manteve-se a metodologia.

Foram adquiridas 75 imagens de cada alimento para o desenvolvimento deste trabalho. Cada uma dessas imagens contém apenas o prato com o alimento em questão, sem outros alimentos inclusos, porém com volumes diferentes, conforme pode ser visto na FIGURA 26.




FIGURA 26 – PRATOS COM DIFERENTES QUANTIDADES DOS MESMOS ALIMENTOS, (a) ARROZ, (b) FEIJÃO, (c) BETERRABA  
FONTE: O autor (2015)

Além das imagens obtidas contendo apenas o prato com um alimento, também foram adquiridas 60 imagens de pratos contendo diversos alimentos juntos. Algumas destas imagens são apresentadas na FIGURA 27.



FIGURA 27 – EXEMPLOS DE PRATOS CONTENDO DIVERSOS ALIMENTOS  
FONTE: O autor (2015)



### 3.3 PRÉ-PROCESSAMENTO

O pré-processamento consiste em remover toda a região da imagem que não será utilizada, mantendo apenas a região de interesse, ou seja, as porções alimentares. A FIGURA 28 apresenta o fluxograma da etapa do pré-processamento.

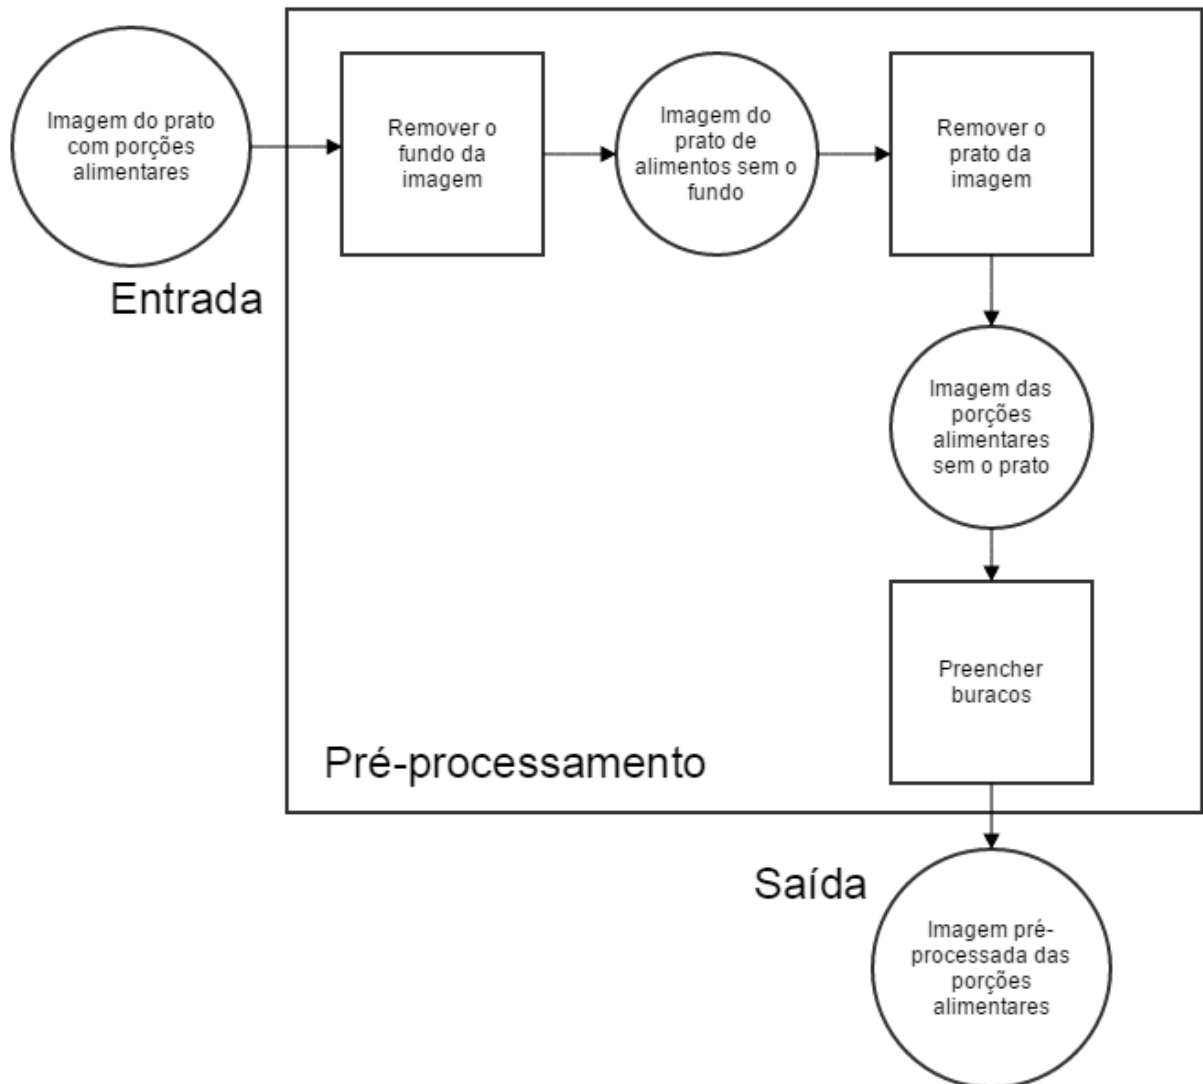


FIGURA 28 – FLUXOGRAMA DA ETAPA DE PRÉ-PROCESSAMENTO  
FONTE: O autor (2015)

A primeira etapa do sistema é responsável por buscar a região de interesse da imagem utilizando a Transformada Circular de Hough, onde o algoritmo procura um círculo na imagem, ou seja, a borda do prato, eliminando o fundo da imagem.

Para esse processo o sistema utiliza a função “imfindcircles” do MATLAB® na imagem do prato em escala de cinzas. Essa função retorna a posição e o raio do

círculo encontrado na imagem e com isso é possível remover todo o conteúdo fora do círculo, restando apenas o prato com as porções alimentares. Os parâmetros utilizados na função foram: tolerância de 95% e diâmetro entre 80% e 100% da altura da imagem.

A FIGURA 29 apresenta um exemplo de uma imagem de um prato com porções alimentares antes desse processo em (a), e depois deste processo em (b).



(a)



(b)

FIGURA 29 – PRATO COM PORÇÕES ALIMENTARES ANTES E DEPOIS DO PROCESSO DE ELIMINAÇÃO DO FUNDO, (a) ANTES, (b) DEPOIS  
FONTE: O autor (2015)

A fim de eliminar o prato da imagem deixando apenas as porções alimentares, o sistema calcula os histogramas dos planos vermelho, verde e azul (RGB) da imagem e verifica o maior pico de cada histograma. Em seguida, o sistema zera cada pixel na imagem que possua seus valores RGB maiores ou iguais ao início dos respectivos picos.

Para exemplificar este processo, os histogramas RGB da imagem na FIGURA 29 (b) são apresentados na FIGURA 30, sendo (a) o histograma do plano vermelho, (b) o histograma do plano verde e (c) o histograma do plano azul. Nesse caso, o maior valor do histograma dos planos vermelho, verde e azul se encontram nos índices 207, 210 e 214 respectivamente.

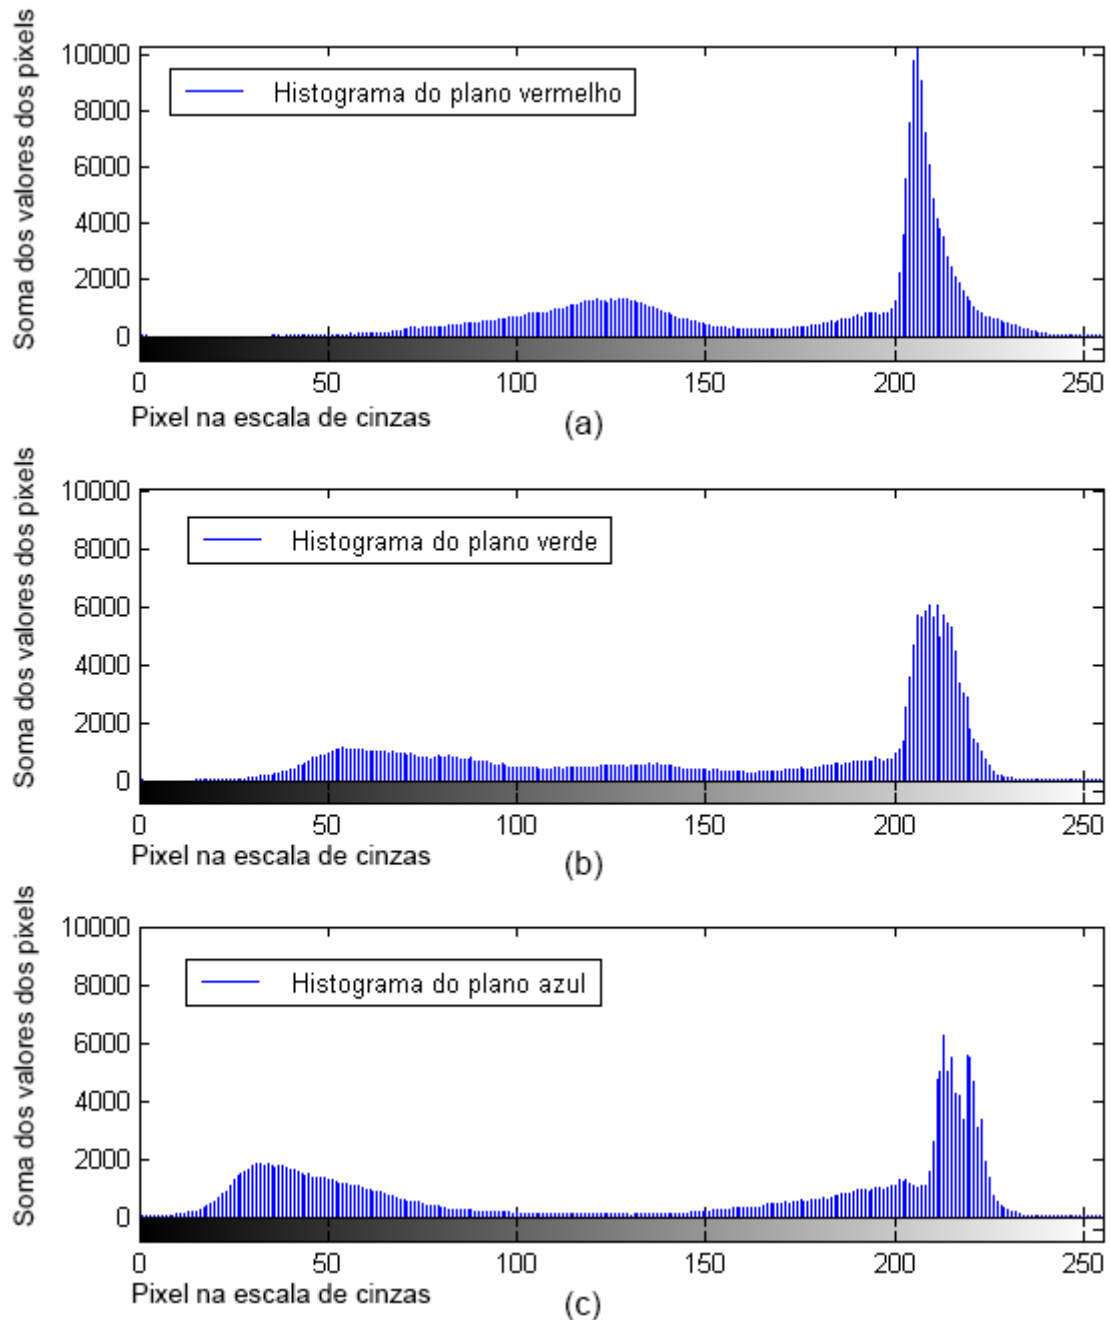


FIGURA 30 – HISTOGRAMAS DE UMA IMAGEM DE UM PRATO COM ALIMENTOS, (a) HISTOGRAMA DO PLANO VERMELHO, (b) HISTOGRAMA DO PLANO VERDE, (c) HISTOGRAMA DO PLANO AZUL

FONTE: O autor (2015)

Em seguida, com o objetivo de se aproximar do início desses picos, o sistema reduz cada índice em 10%, e, por fim, zera todos os pixels nos índices acima. Ou seja, no caso da FIGURA 30, o sistema cria uma condição lógica para eliminar o prato da imagem, zerando todos os pixels com os valores: vermelho maior que 186, verde maior que 189 e azul maior que 193.

Este processo funcionou corretamente nas imagens adquiridas para a base de dados deste trabalho, porém, verificou-se posteriormente que este processo pode não funcionar em uma imagem de um prato cheio de alimentos, de forma que o próprio prato quase não apareça na imagem.

O resultado deste processo é a imagem dos alimentos sem o prato. Porém, alguns elementos importantes da imagem são apagados, conforme mostra a FIGURA 31, sendo (a) a imagem original do prato com alimentos e (b) a imagem após o processo de remoção do prato.




FIGURA 31 – (a) IMAGEM DO PRATO COM ALIMENTOS, (b) IMAGEM DOS ALIMENTOS DEPOIS DO PROCESSO DE ELIMINAÇÃO DO PRATO POR CONDIÇÃO LÓGICA  
FONTE: O autor (2015)

Na FIGURA 31 (b) é possível visualizar que a região central do alimento arroz e algumas partes do alimento maionese foram apagados da imagem. Para solucionar este problema, primeiramente a imagem das porções alimentares sem o prato, apresentada na FIGURA 31 (b), é binarizada, considerando 1 qualquer pixel maior que zero. Em seguida, a função “imfill” do MATLAB®, com o parâmetro *holes*

é utilizada para preencher os buracos da imagem binarizada, conforme apresenta a FIGURA 32.




FIGURA 32 – (a) IMAGEM BINARIZADA DE PORÇÕES ALIMENTARES COM BURACOS, (b) IMAGEM APÓS O PROCESSO DE PREENCHIMENTO DE BURACOS  
FONTE: O autor (2015)

Por fim, o sistema utiliza a imagem obtida como uma máscara binária, a ser aplicada na imagem original do prato com alimentos. A FIGURA 33 exemplifica esse processo, onde (a) é a imagem original do prato com alimentos, (b) é a máscara binária e (c) é o resultado da aplicação da máscara binária (b) em (a).




FIGURA 33 – (a) IMAGEM ARMAZENADA ANTERIORMENTE, (b) MÁSCARA BINÁRIA, (c) RESULTADO DA APLICAÇÃO DA MÁSCARA BINÁRIA NA IMAGEM  
FONTE: O autor (2015)

Com isso, restando apenas a imagem dos alimentos com fundo preto e sem perda de informações.

### 3.4 SEGMENTAÇÃO

Após o pré-processamento, a imagem deve ser segmentada, isto é, os diferentes alimentos do prato devem ser separados. A FIGURA 34 apresenta o fluxograma da etapa de segmentação.

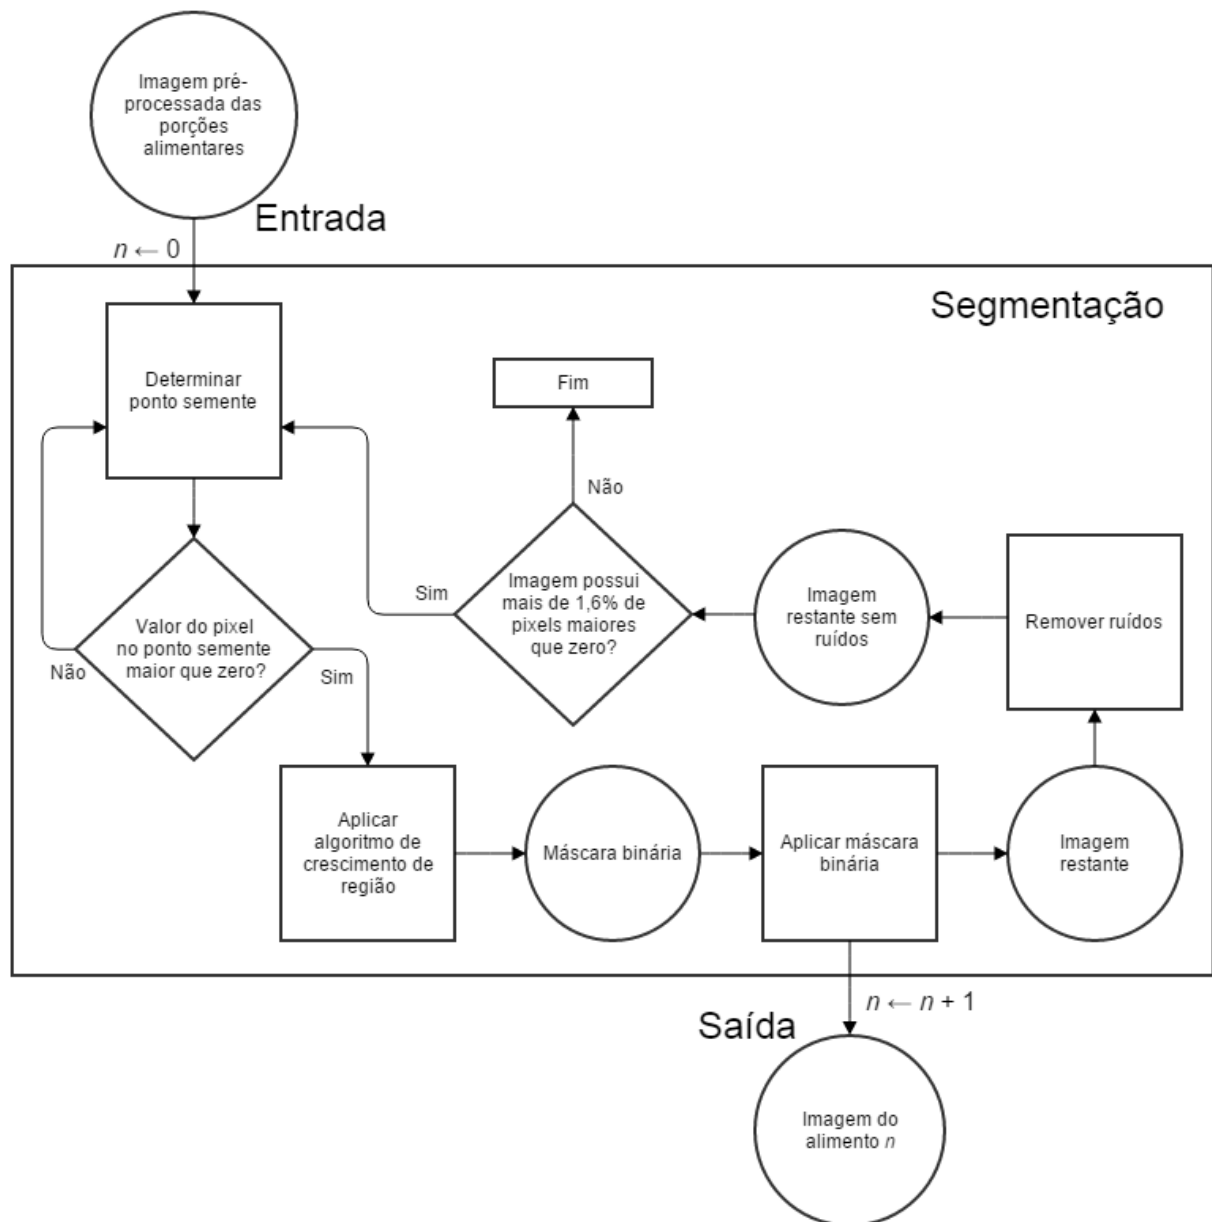


FIGURA 34 – FLUXOGRAMA DA ETAPA DE SEGMENTAÇÃO  
FONTE: O autor (2015)

Para o processo de segmentação, inicialmente deve ser determinado um ponto semente, pois este processo utilizará a técnica de crescimento de região. Para determinar a posição inicial da semente, primeiramente são gerados dois vetores da

soma dos pixels diferentes de zero nas direções horizontal e vertical da imagem. A FIGURA 35 apresenta um exemplo de uma imagem de porções alimentares e seus respectivos gráficos dos vetores mencionados.

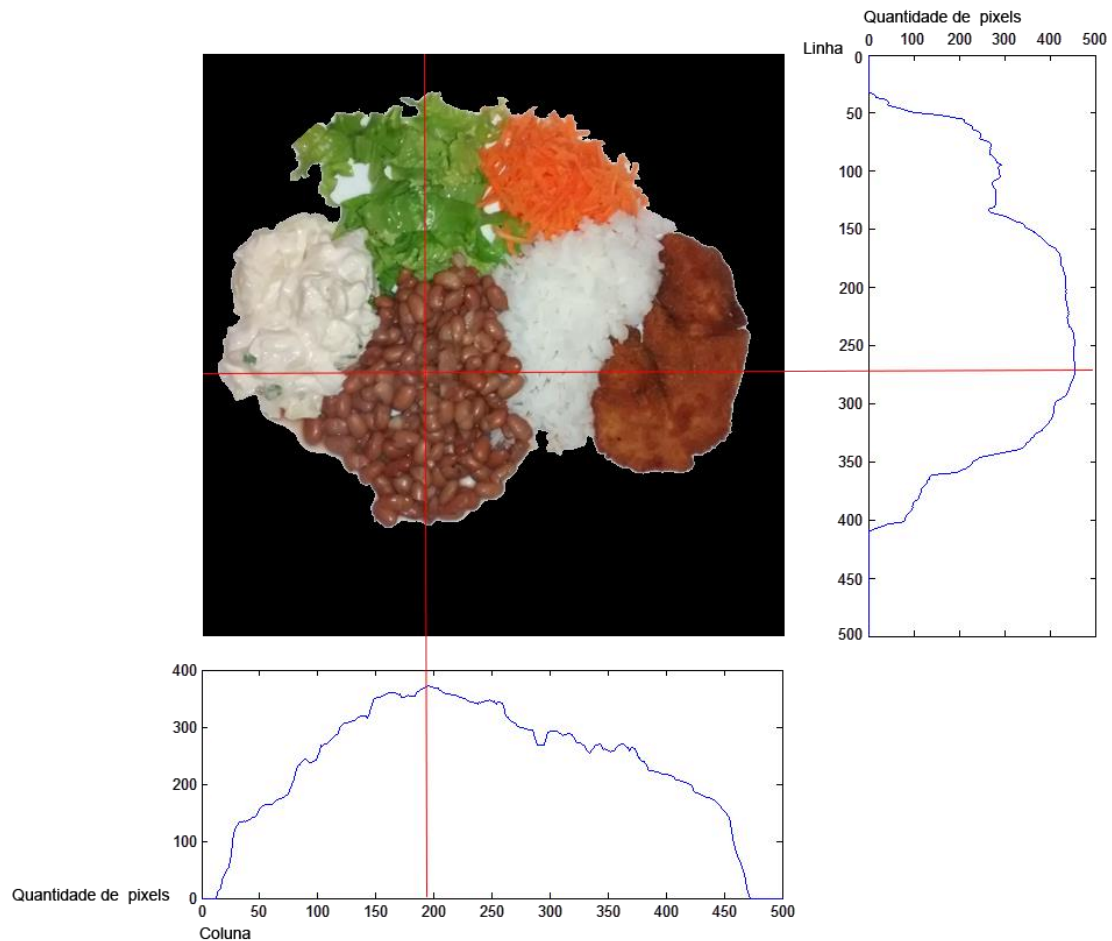


FIGURA 35 – IMAGEM DE ALIMENTOS E SEUS RESPECTIVOS GRÁFICOS RELACIONANDO A SOMATÓRIA DE PIXELS POR LINHA E POR COLUNA  
FONTE: O autor (2015)

Conforme mostra a FIGURA 35, a posição inicial da semente para o crescimento de região é determinada pelo cruzamento dos picos dos vetores (horizontal e vertical) gerados, indicados pelas linhas vermelhas, isto é, a região da imagem que possui a maior concentração de pixels.

Em alguns casos, o valor do pixel determinado para semente pode ser zero, pois em imagens com mais de uma região de interesse, o cruzamento dos picos dos vetores mencionados pode ocorrer em um espaço vazio da imagem conforme ilustra a FIGURA 36.

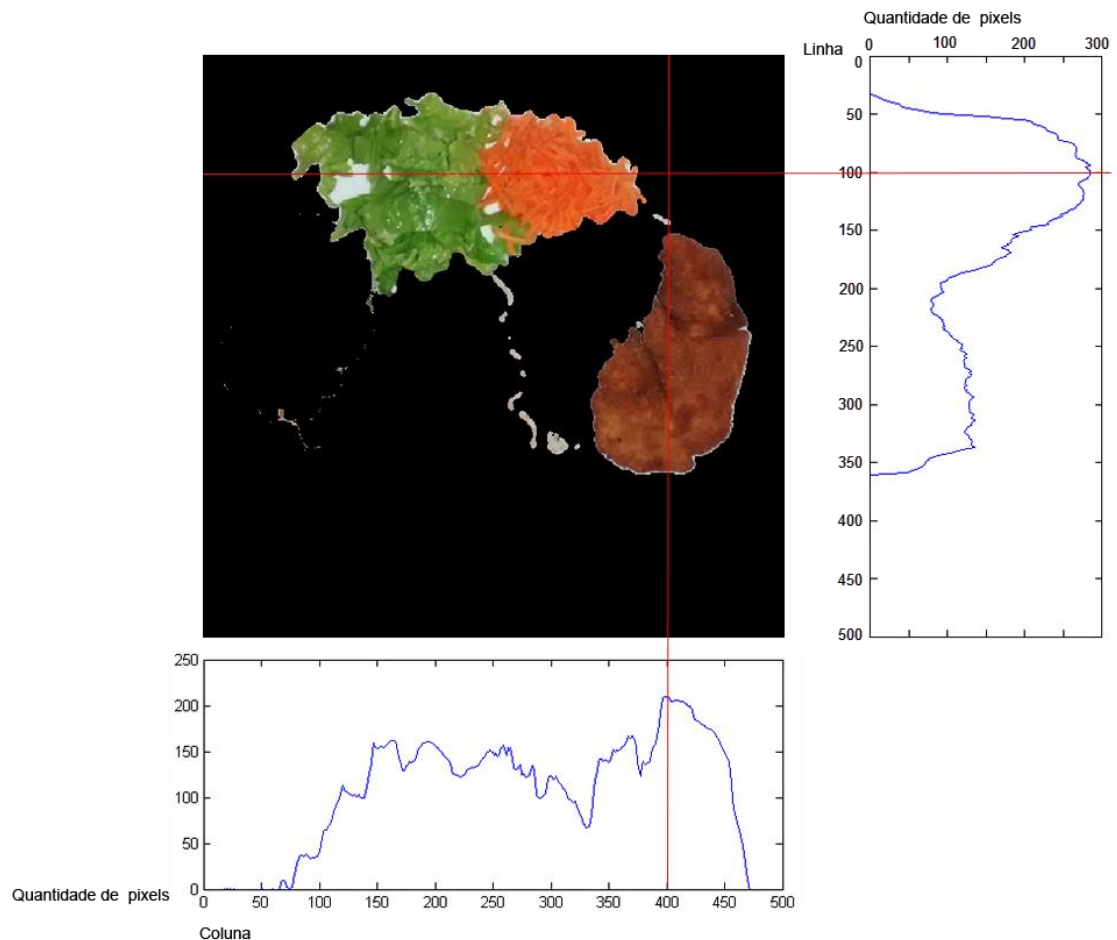


FIGURA 36 – IMAGEM DE ALIMENTOS SEGMENTADA E SEUS RESPECTIVOS GRÁFICOS RELACIONANDO A SOMATÓRIA DE PIXELS POR LINHA E POR COLUNA  
 FONTE: O autor (2015)

Como uma condição de contorno para esses casos, o sistema desenvolvido determina como posição inicial o cruzamento dos próximos maiores picos do vetor, até que este não seja um espaço vazio da imagem, isto é, até que o valor de seu pixel seja maior que zero.

Com a posição inicial da semente já determinada, o sistema separa a imagem em quatro planos distintos para aplicar o algoritmo de crescimento de região. Os três primeiros são os planos RGB da imagem (vermelho, verde e azul) e o quarto é o primeiro plano da imagem convertida para HSV (matiz, saturação e brilho), ou seja, o matiz da imagem. A FIGURA 37 apresenta uma imagem de porções alimentares em (a), e cada um dos planos mencionados, sendo (b) o plano vermelho, (c) o plano verde, (d) o plano azul e (e) o plano matiz.






FIGURA 37 – PLANOS UTILIZADOS PARA O CRESIMENTO DE REGIÕES: (a) IMAGEM ORIGINAL, (b) PLANO VERMELHO, (c) PLANO VERDE, (d) PLANO AZUL, (e) PLANO MATIZ  
 FONTE: O autor (2015)

Em seguida, o sistema realiza individualmente o crescimento de região em cada plano selecionado da imagem, sem limite de distância máxima e com o nível de limiar de 70 pixels para os três primeiros planos (RGB), e 30 pixels para o último

plano (matiz). Os parâmetros utilizados nesse processo foram valores empíricos obtidos baseados em testes efetuados no grupo de imagens adquiridas.

Ou seja, a partir do ponto inicial, o algoritmo percorre cada plano em todos os sentidos enquanto a diferença entre os valores dos pixels encontrados e o valor do pixel na posição inicial for menor que o valor do limiar fornecido, ou até encontrar o limite da região de interesse da imagem, ou seja, a borda das porções alimentares.

Este processo resulta quatro máscaras binárias, isto é, matrizes bidimensionais do tamanho da imagem com valores binários, indicando o valor um (verdadeiro) para os pixels associados ao crescimento da região e o valor zero (falso) para o resto da imagem. A FIGURA 38 apresenta as quatro máscaras binárias geradas da imagem exemplo, sendo (a) o plano vermelho, (b) o plano verde, (c) o plano azul e (d) o plano matiz.




FIGURA 38 – MÁSCARAS OBTIDAS DO CRESCIMENTO DE REGIÃO: (a) PLANO VERMELHO, (b) PLANO VERDE, (c) PLANO AZUL, (d) PLANO MATIZ  
FONTE: O autor (2015)

Com isso é gerada uma máscara binária definitiva, conforme mostrada na FIGURA 39, que é a intersecção das quatro máscaras obtidas anteriormente.




FIGURA 39 – MÁSCARA BINÁRIA RESULTANTE DO PROCESSO DE SEGMENTAÇÃO DE UMA IMAGEM DE PORÇÕES ALIMENTARES  
FONTE: O autor (2015)

A partir dessa máscara obtêm-se duas imagens, exemplificadas na FIGURA 40, onde (a) é a imagem original, (b) é a imagem obtida a partir da parte segmentada da imagem original, nomeada de “imagem do alimento”, e (c) é o resto da imagem, nomeada de “imagem restante”.




FIGURA 40 – IMAGEM DO ALIMENTO E IMAGEM RESTANTE GERADAS A PARTIR DO PROCESSO DE SEGMENTAÇÃO  
FONTE: O autor (2015)

A imagem do alimento é composta apenas do alimento segmentado com o fundo preto, e será utilizada para a extração das características do alimento.

Já a imagem restante passa por um processo de remoção de ruídos. Este processo utiliza um filtro de mediana com máscara de 5 por 5 pixels, removendo apenas os ruídos da imagem e preservando a sua qualidade.

O processo de segmentação ocorre de forma recursiva, iniciando-se novamente a partir da imagem restante. Ao final, gera-se uma nova imagem do alimento e uma nova imagem restante conforme mostra a FIGURA 41.




FIGURA 41 – IMAGENS GERADAS A PARTIR DO PROCESSO DE SEGMENTAÇÃO NA IMAGEM DA FIGURA 40 (b): (a) NOVA IMAGEM DO ALIMENTO, (b) NOVA IMAGEM RESTANTE  
 FONTE: O autor (2015)

Na FIGURA 41, a imagem restante anterior (a) passa pelo processo de segmentação, gerando a imagem do alimento (b), que será utilizada para a extração das características do alimento, e a imagem restante (c), que passará pelo processo de remoção de ruídos e pelo processo de segmentação. A FIGURA 42 apresenta as imagens dos alimentos e as imagens restantes geradas nas próximas interações, a partir da imagem restante obtida na FIGURA 41 (c).




FIGURA 42 – IMAGENS DOS ALIMENTOS E IMAGENS RESTANTES GERADAS A PARTIR DO PROCESSO DE SEGMENTAÇÃO EXECUTANDO DE FORMA RECURSIVA  
FONTE: O autor (2015)

O processo de segmentação ocorre de forma recursiva, até que a imagem restante possua menos que 1,6% de pixels maiores que zero, sobrando apenas alguns ruídos que não puderam ser removidos da imagem. Esse valor foi obtido

após analisar as porções alimentares adquiridas para a base de dados, onde se verificou que a menor porção alimentar obtida ocupa 1,63% da imagem.

O uso do método de crescimento de região neste trabalho se mostrou mais efetivo para a segmentação dos alimentos, comparado a um método utilizado anteriormente, onde o algoritmo JSEG (*J measure based SEGmentation*) foi utilizado para realizar esse processo (SHIGA et al., 2014).

JSEG é um algoritmo criado por Deng et al. (1999), com o intuito de segmentar imagens de maneira totalmente automática em duas etapas independentes: quantização de cores e rotulação por segmentação espacial.

A FIGURA 43 apresenta uma imagem de alimentos sem o fundo (a), segmentada utilizando o algoritmo JSEG (b) - (e) e segmentada utilizando o algoritmo de crescimento de regiões deste trabalho (f) - (j).

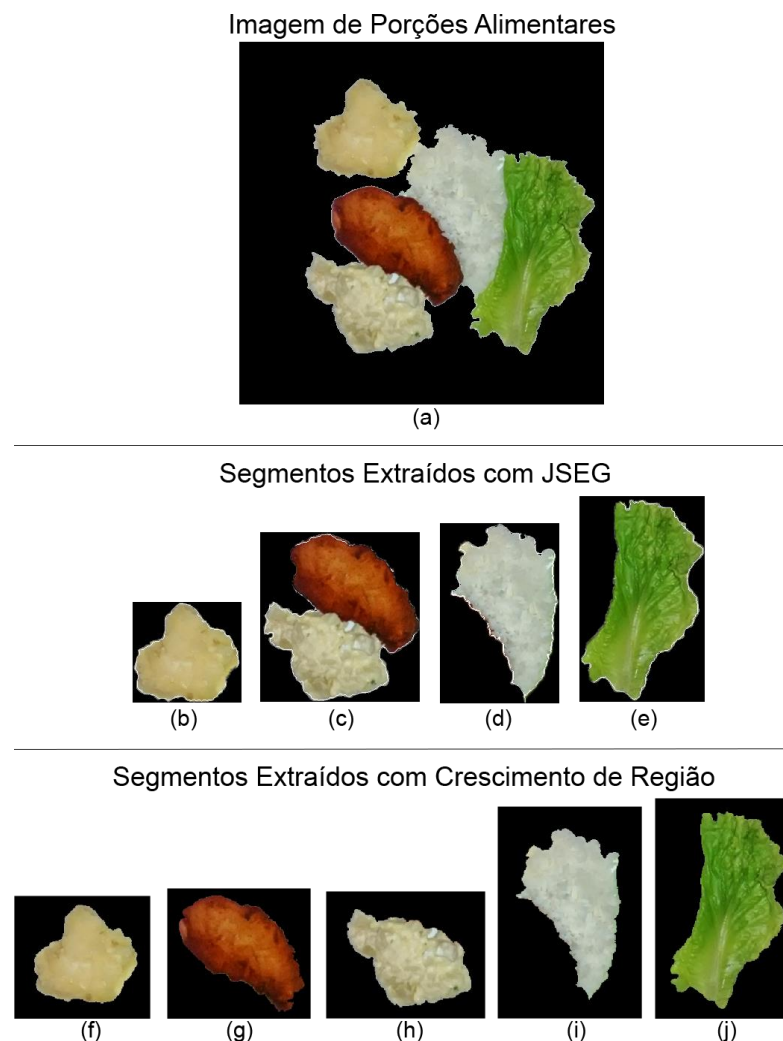


FIGURA 43 – (a) IMAGEM DE ALIMENTOS, (b) - (e) SEGMENTOS EXTRAÍDOS COM JSEG, (f) - (j) SEGMENTOS EXTRAÍDOS COM CRESCIMENTO DE REGIÃO  
FONTE: O autor (2015)

Conforme é possível observar na FIGURA 43, o algoritmo JSEG segmentou incorretamente a imagem (a), deixando dois alimentos diferentes no mesmo segmento, apresentado em (c). Já o crescimento de região segmentou corretamente a imagem (a), separando cada alimento em um segmento diferente.

Além disso, o tempo de processamento para segmentar a imagem utilizando o JSEG foi de 4 minutos e 7 segundos, enquanto o tempo de processamento utilizando o crescimento de região foi de 13 segundos, em uma máquina com processador Intel® Core™ i5-2500K CPU 3,3GHz com 12GB de memória RAM.

### 3.5 EXTRAÇÃO DE CARACTERÍSTICAS

Para cada segmento obtido têm-se suas características extraídas com base em sua cor e textura. Como características para distinguir as cores, foram escolhidas as médias RGB, a média do valor do matiz do segmento e os seus respectivos desvios padrão, ou seja, o valor médio dos pixels nas cores vermelho, verde e azul, juntamente com o valor médio do plano matiz, mais o desvio padrão de cada um. A TABELA 3 apresenta os alimentos utilizados na pesquisa e suas respectivas características extraídas relacionadas à cor.

TABELA 3 – MÉDIA E DESVIO PADRÃO DOS ALIMENTOS ADQUIRIDOS PARA A BASE DE DADOS

Alimento	Média Vermelho ± Desvio Padrão	Média Verde ± Desvio Padrão	Média Azul ± Desvio Padrão	Média Matiz ± Desvio Padrão
Alface	106 ±25	141 ±20	58 ±28	60 ±4
Almôndega	81 ±18	45 ±17	40 ±17	87 ±86
Arroz Branco	188 ±7	181 ±7	167 ±8	34 ±15
Batata Frita	174 ±18	125 ±26	60 ±31	24 ±7
Beterraba	60 ±26	21 ±27	35 ±29	238 ±14
Bife Bovino na Chapa	97 ±24	61 ±23	60 ±23	112 ±101
Carne Bovina de Panela	137 ±28	80 ±29	51 ±28	14 ±10
Cenoura	209 ±11	83 ±25	31 ±29	12 ±4
Feijão Carioca	100 ±22	67 ±22	57 ±21	18 ±17
Macarrão	176 ±20	110 ±27	49 ±30	20 ±2

continua

TABELA 3 – MÉDIA E DESVIO PADRÃO DOS ALIMENTOS ADQUIRIDOS PARA A BASE DE DADOS

Alimento	Média Vermelho ± Desvio Padrão	Média Verde ± Desvio Padrão	Média Azul ± Desvio Padrão	continuação
				Média Matiz ± Desvio Padrão
Maionese	179 ±15	176 ±14	145 ±16	41 ±9
Peito de Frango a Milanese	122 ±28	50 ±19	26 ±16	60 ±59
Purê de Batatas	176 ±12	164 ±11	112 ±14	35 ±4
Estrogonofe de Carne	151 ±21	84 ±24	42 ±25	16 ±5
Estrogonofe de Frango	190 ±17	115 ±24	66 ±27	17 ±3
Tomate	187 ±19	80 ±38	63 ±36	72 ±71

FONTE: O autor (2015)

Já para as características de textura, utilizou-se o vetor normalizado do histograma LPQ da região em escala de cinzas. Os parâmetros de entrada utilizados no algoritmo gerador do histograma LPQ foram os padrões apresentados pelos seus criadores Ojansivu e Heikkilä (2008). Estes parâmetros são: a imagem do segmento em escala de cinzas, tamanho da janela local de 9 pixels (3 por 3 pixels), transformada de Fourier com janela uniforme, histograma normalizado e invariância de rotação.

O histograma LPQ é um vetor de números inteiros com 256 posições. Para a utilização do histograma LPQ na classificação das imagens, a posição zero deste vetor deve ser desconsiderada, pois se trata dos pixels com os valores RGB nulos, ou seja, o fundo preto da imagem. Assim, restando um vetor de 255 posições.

Nesse vetor, são concatenadas as características relacionadas à cor do alimento, ou seja, o valor médio dos pixels nas cores vermelho, verde e azul, a média do valor do plano matiz e seus respectivos desvios padrão. Formando assim, um vetor de 263 posições, que é utilizado como a característica do alimento na rede Bayesiana. Esse processo é chamado de fusão de características com concatenação simples.

### 3.6 CLASSIFICAÇÃO

A classificação dos alimentos é realizada por um classificador que utilizará as características de cor e textura para esse fim. Como classificador, foi utilizada uma rede Bayesiana com 263 variáveis de entrada, sendo 8 variáveis de cor e 255



variáveis de textura, e uma variável de saída, que é o tipo do alimento a ser classificado.

O treinamento da rede foi realizado utilizando as imagens com apenas uma porção alimentar no prato, ou seja, as 75 imagens de cada um dos 16 alimentos obtidos para a base de dados, totalizando 1200 amostras. A TABELA 4 apresenta os alimentos e suas respectivas quantidades de imagens utilizadas para o treinamento da rede Bayesiana.

TABELA 4 – ALIMENTOS E A QUANTIDADE DE IMAGENS UTILIZADAS PARA O TREINAMENTO DA REDE BAYESIANA

Alimento	Quantidade de Imagens Utilizadas no Treinamento da Rede Bayesiana
Alface	75
Almôndega	75
Arroz Branco	75
Batata Frita	75
Beterraba	75
Bife Bovino na Chapa	75
Carne Bovina de Panela	75
Cenoura	75
Feijão Carioca	75
Macarrão	75
Maionese	75
Peito de Frango a Milanese	75
Purê de Batatas	75
Estrogonofe de Carne	75
Estrogonofe de Frango	75
Tomate	75
Total	1200

FONTE: O autor (2015)

Cada uma dessas imagens foi pré-processada e segmentada conforme o algoritmo descrito anteriormente, resultando em 1200 imagens apenas com o alimento e fundo preto.

Em seguida, o sistema calculou as médias e os desvios padrão dos valores dos pixels nos planos vermelho, verde, azul e matiz e o histograma LPQ de cada imagem de porção alimentar, desconsiderando o fundo preto, para compor um vetor

de 263 posições para cada segmento, totalizando 1200 vetores com 263 posições cada.

Cada vetor foi classificado de acordo com o alimento correspondente, e utilizado para gerar a rede Bayesiana, utilizando o *Waikato Environment for Knowledge Analysis* (WEKA). Este programa foi desenvolvido em plataforma Java para resolver problemas de mineração de dados baseado em aprendizagem de máquinas (WITTEN E FRANK, 2005).

O ambiente WEKA automaticamente realiza os cálculos necessários para preencher as tabelas de probabilidade condicionais necessárias para a rede Bayesiana. Com isso, obtém-se uma rede Bayesiana treinada, capaz de informar qual é o alimento (saída), a partir de um vetor de características com 263 posições (entrada).

A rede Bayesiana treinada no ambiente WEKA foi exportada para a aplicação Netica®, uma ferramenta desenvolvida para trabalhar com redes Bayesianas e diagramas de influência (NORSYS SOFTWARE CORP., 1997). Essa ferramenta possui a capacidade de realizar uma análise de sensibilidade aprofundada em cada característica na rede Bayesiana, a fim de apresentar o grau de importância de cada variável de entrada utilizada na rede. A TABELA 5 apresenta as 30 características mais relevantes para a classificação dos alimentos e a porcentagem de impacto de cada característica em relação a classe.

TABELA 5 – CARACTERÍSTICAS DE MAIOR IMPORTÂNCIA PARA A CLASSIFICAÇÃO DOS ALIMENTOS

Característica	Impacto da Característica em Relação a Classe
Média Verde	40,0%
Média Vermelho	36,4%
Média Matiz	35,3%
Desvio Vermelho	28,7%
LPQ_108	28,6%
LPQ_235	28,5%
Média Azul	28,5%
LPQ_251	28,3%

continua

TABELA 5 – CARACTERÍSTICAS DE MAIOR IMPORTÂNCIA PARA A CLASSIFICAÇÃO DOS ALIMENTOS

continuação

Característica	Impacto da Característica em Relação a Classe
LPQ_107	28,3%
LPQ_109	27,6%
LPQ_59	27,6%
LPQ_110	27,3%
LPQ_223	27,0%
Desvio Matiz	26,6%
LPQ_207	26,3%
LPQ_78	26,1%
LPQ_187	26,1%
LPQ_44	25,7%
LPQ_172	25,7%
LPQ_121	25,4%
LPQ_205	25,3%
Desvio Verde	25,3%
LPQ_60	25,3%
LPQ_77	25,0%
LPQ_123	25,0%
LPQ_58	24,9%
Desvio Azul	24,9%
LPQ_221	24,8%
LPQ_204	24,4%
LPQ_57	24,2%

FONTE: O autor (2015)

Conforme é possível observar na TABELA 5, as características mais relevantes para a rede Bayesiana classificar os alimentos são: média no plano verde, média no plano vermelho, média no plano matiz, desvio padrão do plano vermelho e a posição 108 do histograma LPQ.

## 4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta diversos testes realizados com a rede Bayesiana treinada no capítulo anterior, e a discussão desses resultados. As técnicas de avaliação utilizadas na análise foram: validação cruzada, percentual de divisão e conjunto de teste fornecido.

### 4.1 TESTES COM VALIDAÇÃO CRUZADA

Os testes a seguir foram realizados na rede Bayesiana treinada, apresentada no capítulo 3.6, utilizando a técnica de validação cruzada e o método *k-fold*, com valor 10 para a variável *k*, valor sugerido como padrão pelo WEKA (BOUCKAERT et al., 2010). Nesse método, o conjunto de dados foi dividido em *k* subconjuntos de tamanhos iguais e, por *k* vezes, cada subconjunto foi usado para teste, enquanto os demais são usados para treinamento. A aplicação WEKA determina de forma aleatória quais amostras serão utilizadas para treinamento e quais amostras serão utilizadas para testes, por isso, cada teste apresentado a seguir foi realizado cinco vezes, com a finalidade de verificar a variação dos resultados obtidos.

#### 4.1.1 Validação Cruzada Utilizando as Características Relacionadas à Cor

Nos testes a seguir, utilizaram-se apenas as características relacionadas à cor dos alimentos, ou seja, as médias dos valores dos pixels nos planos vermelho, verde, azul e matiz de cada alimento, e seus respectivos desvios padrão, formando um vetor de características de 8 posições para cada uma das 1200 amostras. A TABELA 6 apresenta o percentual de amostras classificadas corretamente de cada teste realizado, com destaque para o melhor resultado.

TABELA 6 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO AS CARACTERÍSTICAS DE COR

Teste	Percentual de Amostras Classificadas Corretamente
Teste 1	93,50%
Teste 2	93,67%
<b>Teste 3</b>	<b>93,91%</b>
Teste 4	93,83%
Teste 5	93,50%
Média ± Desvio Padrão	93,68% ±0,18%

FONTE: O autor (2015)

O melhor resultado obtido nos testes com validação cruzada utilizando apenas as características relacionadas à cor dos alimentos foi de 93,91% de taxa de acerto.

#### 4.1.2 Validação Cruzada Utilizando as Características Relacionadas à Textura

Nos testes a seguir, utilizaram-se apenas as características relacionadas à textura dos alimentos, ou seja, os 255 elementos do vetor do histograma LPQ de cada alimento, formando um vetor de características de 255 posições para cada uma das 1200 amostras. A TABELA 7 apresenta o percentual de amostras classificadas corretamente de cada teste realizado, com destaque para o melhor resultado.

TABELA 7 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO AS CARACTERÍSTICAS DE TEXTURA

Teste	Percentual de Amostras Classificadas Corretamente
Teste 1	93,33%
Teste 2	93,16%
Teste 3	93,00%
<b>Teste 4</b>	<b>93,50%</b>
Teste 5	93,16%
Média ± Desvio Padrão	93,23% ±0,19%

FONTE: O autor (2015)

O melhor resultado obtido nos testes com validação cruzada utilizando apenas as características relacionadas à textura dos alimentos foi de 93,50% de taxa de acerto.

#### 4.1.3 Validação Cruzada Utilizando a Fusão das Características

Nos testes a seguir, utilizou-se a fusão das características de cor e textura, com concatenação simples, ou seja, para cada amostra, o vetor de características de cor, com 8 posições, foi concatenado com o vetor de características de textura, com 255 posições, formando um único vetor de características com 263 posições. A TABELA 8 apresenta o percentual de amostras classificadas corretamente de cada teste realizado, com destaque para o melhor resultado.

TABELA 8 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO A FUSÃO DAS CARACTERÍSTICAS DE COR E TEXTURA

Teste	Percentual de Amostras Classificadas Corretamente
<b>Teste 1</b>	<b>96,00%</b>
Teste 2	95,58%
Teste 3	95,25%
Teste 4	95,50%
Teste 5	95,83%
Média ± Desvio Padrão	95,63% ±0,29%

FONTE: O autor (2015)

O melhor resultado obtido nos testes com validação cruzada utilizando a fusão das características dos alimentos foi de 96,00% de taxa de acerto.

#### 4.1.4 Discussão dos Testes com Validação Cruzada

Em testes realizados anteriormente (SHIGA et al., 2014), algumas das características dos descritores de Haralick foram utilizadas como características de textura dos alimentos. Porém, a utilização desse método apresentou piores resultados na base de dados adquirida para este trabalho, comparado ao LPQ.

No artigo de Shiga et al. (2014), utilizou-se 15 imagens de 9 alimentos diferentes, já neste trabalho, a base de dados aumentou para 75 imagens de 16 alimentos diferentes.

A TABELA 9 apresenta testes realizados na base de dados deste trabalho, utilizando apenas as características de textura do Haralick e do LPQ, com a técnica de validação cruzada.

TABELA 9 – TESTES REALIZADOS COM A TÉCNICA DE VALIDAÇÃO CRUZADA PARA COMPARAR AS CARACTERÍSTICAS DE TEXTURA HARALICK E LPQ

Teste	Percentual de Acerto Utilizando Haralick	Percentual de Acerto Utilizando LPQ
Teste 1	70,00%	93,33%
Teste 2	71,25%	93,16%
Teste 3	70,41%	93,00%
Teste 4	69,58%	93,50%
Teste 5	68,75%	93,16%
Média ± Desvio Padrão	70,00% ±1,25%	93,23% ±0,19%

FONTE: O autor (2015)

Conforme é possível observar na TABELA 9, o melhor teste utilizando os descritores de Haralick obteve 71,25% de acerto, enquanto o melhor teste utilizando o descritor LPQ obteve um resultado de 93,50%. Tendo em vista a superioridade dos resultados utilizando o LPQ, em relação ao Haralick, optou-se por utilizar o LPQ como descritor de textura deste trabalho.

Analisando os testes efetuados com a técnica de validação cruzada, é possível perceber que, os testes realizados utilizando apenas as características de cor tiveram melhor resultado que os testes realizados utilizando apenas as características de textura. Porém, com a fusão das características de cor e textura, a taxa de acerto foi superior aos testes realizados com as características de cor e textura separadamente.

Outro ponto observado foi a similaridade entre os resultados obtidos e o baixo desvio padrão da média desses resultados, indicando que a base de dados adquirida para este trabalho é representativa, ou seja, a base de dados possui uma boa distribuição em todo o conjunto composto por 16 alimentos.

Para uma análise mais aprofundada da rede Bayesiana nos testes com validação cruzada, o teste utilizando a fusão de características que obteve melhor resultado será analisado, ou seja, o “Teste 1” apresentado na TABELA 8.

Esse teste obteve uma taxa de acerto de 96,00%, isto é, das 1200 amostras testadas, 1152 foram classificadas corretamente e 48 foram classificadas incorretamente. A TABELA 10 mostra os alimentos testados e suas respectivas taxas de acerto.

TABELA 10 – ALIMENTOS TESTADOS E SUAS TAXAS DE ACERTO NO TESTE REALIZADO COM VALIDAÇÃO CRUZADA

Alimento	Quantidade de Amostras Testadas	Quantidade de Amostras Classificadas Corretamente	Quantidade de Amostras Classificadas Incorretamente	Percentual de Amostras Classificadas Corretamente
Alface	75	75	0	100%
Almôndega	75	67	8	89,3%
Arroz Branco	75	75	0	100%
Batata Frita	75	75	0	100%
Beterraba	75	74	1	98,7%
Bife Bovino na Chapa	75	67	8	89,3%
Carne Bovina de Panela	75	59	16	78,7%
Cenoura	75	75	0	100%
Feijão Carioca	75	75	0	100%
Macarrão	75	75	0	100%
Maionese	75	72	3	96,0%
Peito de Frango a Milanese	75	73	2	97,3%
Purê de Batatas	75	75	0	100%
Estrogonofe de Carne	75	71	4	94,7%
Estrogonofe de Frango	75	74	1	98,7%
Tomate	75	70	5	93,3%
TOTAL	1200	1152	48	96,0%

FONTE: O autor (2015)

No teste em questão, dos 16 tipos de alimentos testados, 7 tiveram uma classificação de 100%, isto é, das 75 amostras de cada um destes alimentos, todas as 75 foram classificadas corretamente. Estes alimentos são: alface, arroz branco, batata frita, cenoura, feijão carioca, macarrão e purê de batatas.



O alimento com menor taxa de acerto foi a carne bovina de panela, com um percentual de amostras classificadas corretamente de 78,7%, isto é, das 75 amostras testadas deste alimento, 59 foram classificadas corretamente e 16 foram classificadas incorretamente. A FIGURA 44 apresenta a matriz de confusão do teste em questão.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	<-- classificação
75	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a = Alface
0	67	0	0	0	0	8	0	0	0	0	0	0	0	0	0	b = Almôndega
0	0	75	0	0	0	0	0	0	0	0	0	0	0	0	0	c = Arroz Branco
0	0	0	75	0	0	0	0	0	0	0	0	0	0	0	0	d = Batata Frita
0	1	0	0	74	0	0	0	0	0	0	0	0	0	0	0	e = Beterraba
0	0	0	0	0	67	2	0	0	0	0	0	0	6	0	0	f = Bife Bovino na Chapa
1	8	0	0	0	0	59	0	0	0	0	0	0	7	0	0	g = Carne Bovina de Panela
0	0	0	0	0	0	0	75	0	0	0	0	0	0	0	0	h = Cenoura
0	0	0	0	0	0	0	0	75	0	0	0	0	0	0	0	i = Feijao Carioca
0	0	0	0	0	0	0	0	0	75	0	0	0	0	0	0	j = Macarrão
0	0	0	0	0	0	0	0	0	0	72	0	3	0	0	0	k = Maionese
0	0	0	0	0	2	0	0	0	0	0	73	0	0	0	0	l = Peito de Frango à Milanese
0	0	0	0	0	0	0	0	0	0	0	0	75	0	0	0	m = Purê de Batatas
0	0	0	0	0	0	2	0	2	0	0	0	0	71	0	0	n = Estrogonofe de Carne
1	0	0	0	0	0	0	0	0	0	0	0	0	0	74	0	o = Estrogonofe de Frango
0	0	0	0	0	0	4	0	0	0	0	0	0	1	0	70	p = Tomate

FIGURA 44 – MATRIZ DE CONFUSÃO DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA  
FONTE: O autor (2015)

Conforme é possível observar na matriz de confusão na FIGURA 44, no teste em questão, das 75 amostras testadas do alimento carne bovina de panela, 8 foram classificadas como almôndega, 7 foram classificadas como estrogonofe de carne e 1 foi classificada como alface.

Ao observar o caso específico no qual o alimento carne bovina de panela foi classificado como alface, notou-se que a imagem da carne bovina de panela encontrava-se desfocada e borrada. Geralmente, esse tipo de caso é considerado como ruído na base de dados, e na mineração de dados, na etapa de limpeza de dados, é comum ao verificar um valor atípico, removê-lo manualmente da base de dados, a fim de eliminar algo que possa estar confundindo a rede (WITTEN E FRANK, 2005).

A aplicação WEKA calcula automaticamente a área sob a curva ROC, a sensibilidade e a especificidade de cada alimento nos testes efetuados. A TABELA 11 apresenta esses valores para o teste em questão.

TABELA 11 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC, SENSIBILIDADES E ESPECIFICIDADES DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA

Alimento	Área sob a curva ROC	Sensibilidade	Especificidade
Alface	1	1	0,002
Almôndega	0,998	0,893	0,008
Arroz Branco	1	1	0
Batata Frita	1	1	0
Beterraba	1	0,987	0
Bife Bovino na Chapa	0,997	0,893	0,002
Carne Bovina de Panela	0,990	0,787	0,014
Cenoura	1	1	0
Feijão Carioca	1	1	0,002
Macarrão	1	1	0
Maionese	0,998	0,960	0
Peito de Frango a Milanese	1	0,973	0
Purê de Batatas	0,999	1	0,003
Estrogonofe de Carne	0,997	0,947	0,012
Estrogonofe de Frango	1	0,987	0
Tomate	1	0,933	0
MÉDIA TOTAL	0,999	0,960	0,003

FONTE: O autor (2015)

Conforme apresenta a TABELA 11, a sensibilidade média da rede é de 0,960, mostrando uma alta probabilidade da rede para classificar corretamente os alimentos. A especificidade média da rede é de 0,003, mostrando a baixa probabilidade da rede para classificar incorretamente os alimentos.

A área sob a curva ROC do alimento que apresentou a pior taxa de acerto (carne bovina de panela) é de 0,990 e a média da área sob a curva ROC de todos os alimentos testados é de 0,999. Esses valores, por estarem próximos do valor 1, indicam que a rede Bayesiana utilizada neste trabalho possui um alto grau de confiabilidade.

#### 4.2 TESTE COM CONJUNTO DE TESTE FORNECIDO

Para a análise seguinte, utilizou-se para os testes na rede, a base de dados com as imagens com diversos alimentos no prato. Cada uma dessas imagens foi segmentada conforme o sistema descrito, tornando-se um conjunto de diversas imagens compostas apenas do alimento com o fundo preto.

Em seguida, o sistema calculou as médias e os desvios padrão dos valores dos pixels nos planos vermelho, verde, azul e matiz e o histograma LPQ de cada imagem do alimento, desconsiderando o fundo preto, para compor um vetor de 263 posições para cada segmento.

Cada vetor foi classificado de acordo com o alimento correspondente, e utilizado como um conjunto de teste para avaliar a rede Bayesiana treinada. Totalizando, assim, 1200 amostras para o treinamento da rede e 240 amostras para os testes, conforme exemplifica a TABELA 12, que apresenta a quantidade de alimentos utilizados para treinamento e teste da rede Bayesiana.

TABELA 12 – ALIMENTOS E A QUANTIDADE DE AMOSTRAS UTILIZADAS PARA TREINAMENTO E TESTE

Alimento	Quantidade de Amostras Utilizadas para Treinamento	Quantidade de Amostras Utilizadas para Teste
Alface	75	15
Almôndega	75	15
Arroz Branco	75	15
Batata Frita	75	15
Beterraba	75	15
Bife Bovino na Chapa	75	15
Carne Bovina de Panela	75	15
Cenoura	75	15
Feijão Carioca	75	15
Macarrão	75	15
Maionese	75	15
Peito de Frango a Milanese	75	15
Purê de Batatas	75	15
Estrogonofe de Carne	75	15
Estrogonofe de Frango	75	15
Tomate	75	15
TOTAL	1200	240

FONTE: O autor (2015)

Após a execução dos testes, obteve-se um resultado de 90,42% de amostras classificadas corretamente.

#### 4.2.1 Discussão do Teste com Conjunto de Teste Fornecido

No teste efetuado com um conjunto de teste fornecido, das 240 amostras testadas, 217 foram classificadas corretamente e 23 foram classificadas incorretamente. A TABELA 13 mostra os alimentos testados e suas respectivas taxas de acerto.

TABELA 13 – ALIMENTOS TESTADOS E SUAS TAXAS DE ACERTO NO TESTE REALIZADO COM CONJUNTO DE TESTE FORNECIDO

Alimento	Quantidade de Amostras Testadas	Quantidade de Amostras Classificadas Corretamente	Quantidade de Amostras Classificadas Incorretamente	Percentual de Amostras Classificadas Corretamente
Alface	15	15	0	100%
Almôndega	15	12	3	80%
Arroz Branco	15	9	6	60%
Batata Frita	15	15	0	100%
Beterraba	15	15	0	100%
Bife Bovino na Chapa	15	13	2	86,67%
Carne Bovina de Panela	15	13	2	86,67%
Cenoura	15	15	0	100%
Feijão Carioca	15	14	1	93,33%
Macarrão	15	15	0	100%
Maionese	15	15	0	100%
Peito de Frango a Milanesa	15	14	1	93,33%
Purê de Batatas	15	12	3	80%
Estrogonofe de Carne	15	12	3	80%
Estrogonofe de Frango	15	15	0	100%
Tomate	15	13	2	86,67%
TOTAL	240	217	23	90,42%

FONTE: O autor (2015)

No teste em questão, dos 16 tipos de alimentos testados, 7 tiveram uma classificação de 100%, isto é, das 15 amostras de cada um destes alimentos, todas as 15 foram classificadas corretamente. Estes alimentos são: alface, batata frita, beterraba, cenoura, macarrão, maionese e estrogonofe de carne.

O alimento com menor taxa de acerto foi o arroz branco, com um percentual de amostras classificadas corretamente de 60,0%, isto é, das 15 amostras testadas deste alimento, 9 foram classificadas corretamente e 6 foram classificadas incorretamente. A FIGURA 45 apresenta a matriz de confusão do teste em questão.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	<-- classificação
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a = Alface
0	12	0	0	0	0	3	0	0	0	0	0	0	0	0	0	b = Almôndega
0	0	9	0	0	0	0	0	0	0	0	0	6	0	0	0	c = Arroz Branco
0	0	0	15	0	0	0	0	0	0	0	0	0	0	0	0	d = Batata Frita
0	0	0	0	15	0	0	0	0	0	0	0	0	0	0	0	e = Beterraba
0	0	0	0	0	13	1	0	0	0	0	0	0	1	0	0	f = Bife Bovino na Chapa
0	2	0	0	0	0	13	0	0	0	0	0	0	0	0	0	g = Carne Bovina de Panela
0	0	0	0	0	0	0	15	0	0	0	0	0	0	0	0	h = Cenoura
0	0	0	0	0	0	0	0	14	0	0	0	0	1	0	0	i = Feijao Carioca
0	0	0	0	0	0	0	0	0	15	0	0	0	0	0	0	j = Macarrão
0	0	0	0	0	0	0	0	0	0	15	0	0	0	0	0	k = Maionese
0	0	0	0	0	0	0	0	0	0	0	14	0	0	0	1	l = Peito de Frango à Milanese
0	0	0	0	0	0	0	0	0	0	3	0	12	0	0	0	m = Purê de Batatas
0	0	0	0	0	0	2	0	0	0	0	0	12	1	0	0	n = Estrogonofe de Carne
0	0	0	0	0	0	0	0	0	0	0	0	0	15	0	0	o = Estrogonofe de Frango
0	0	0	0	0	0	2	0	0	0	0	0	0	0	13	0	p = Tomate

FIGURA 45 – MATRIZ DE CONFUSÃO DO TESTE REALIZADO UTILIZANDO UM CONJUNTO DE TESTE FORNECIDO  
FONTE: O autor (2015)

Conforme é possível observar na matriz de confusão da FIGURA 45, das 15 amostras do alimento arroz, 6 foram classificadas como purê de batatas, e das 15 amostras do alimento purê de batatas, 3 foram classificadas como maionese.

A TABELA 14 apresenta os alimentos testados e suas respectivas áreas sob a curva ROC, calculadas automaticamente pela aplicação WEKA, do teste realizado com conjunto de teste fornecido.

TABELA 14 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC DO TESTE REALIZADO COM CONJUNTO DE TESTE FORNECIDO

Alimento	Área sob a curva ROC	Sensibilidade	Especificidade
Alface	1	1	0
Almôndega	0,987	0,800	0,009
Arroz Branco	1	0,600	0
Batata Frita	1	1	0
Beterraba	1	1	0

continua

TABELA 14 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC DO TESTE REALIZADO COM CONJUNTO DE TESTE FORNECIDO

Alimento	Área sob a curva ROC	Sensibilidade	continuação
			Especificidade
Bife Bovino na Chapa	0,997	0,867	0
Carne Bovina de Panela	0,982	0,867	0,036
Cenoura	1	1	0
Feijão Carioca	1	0,933	0
Macarrão	1	1	0
Maionese	0,996	1	0,013
Peito de Frango a Milanesa	1	0,933	0
Purê de Batatas	0,991	0,800	0,027
Estrogonofe de Carne	0,991	0,800	0,009
Estrogonofe de Frango	1	1	0,004
Tomate	0,998	0,867	0,004
MÉDIA TOTAL	0,996	0,904	0,006

FONTE: O autor (2015)

Conforme apresenta a TABELA 14, a sensibilidade média da rede é de 0,904, mostrando uma alta probabilidade da rede para classificar corretamente os alimentos. A especificidade média da rede é de 0,006, mostrando a baixa probabilidade da rede para classificar incorretamente os alimentos.

A área sob a curva ROC do alimento que apresentou a pior taxa de acerto (arroz branco) é 1 e a média da a área sob a curva ROC de todos os alimentos testados é 0,996. Novamente, esses valores indicam o alto grau de confiabilidade da rede Bayesiana utilizada neste trabalho.

#### 4.3 TESTES COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO

Para a análise seguinte, utilizou-se para o treinamento da rede Bayesiana as características extraídas das imagens com apenas uma porção alimentar no prato, juntamente com as características extraídas das imagens com diversos alimentos no prato. Isto é, o conjunto de dados utilizado para treinamento e o conjunto de dados utilizado para testes no capítulo 4.2 foram agregados, formando assim um único conjunto de dados para o treinamento da rede Bayesiana.

Esse conjunto de dados, chamado de conjunto de dados ampliado, totaliza 1440 amostras, sendo 90 amostras de cada um dos 16 alimentos utilizados no trabalho.

A análise a seguir foi realizada utilizando a técnica de validação cruzada e o método k-fold, com valor 10 para a variável k, valor sugerido como padrão pelo WEKA (BOUCKAERT et al., 2010). A aplicação WEKA determina quais amostras serão treinadas e testadas de forma aleatória, por isso, o teste apresentado a seguir foi realizado cinco vezes, com a finalidade de verificar a variação dos resultados obtidos.

Nos testes a seguir, utilizou-se a fusão das características de cor e textura, com concatenação simples, ou seja, para cada amostra, o vetor de características de cor, com 8 posições, foi concatenado com o vetor de características de textura, com 255 posições, formando um único vetor de características com 263 posições. A TABELA 15 apresenta o percentual de amostras classificadas corretamente de cada teste realizado, com destaque para o melhor resultado.

TABELA 15 – AMOSTRAS CLASSIFICADAS CORRETAMENTE COM A TÉCNICA DE VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO

Teste	Percentual de Amostras Classificadas Corretamente
Teste 1	96,18%
Teste 2	96,11%
Teste 3	96,31%
<b>Teste 4</b>	<b>96,39%</b>
Teste 5	96,31%
Média ± Desvio Padrão	96,26% ±0,11%

FONTE: O autor (2015)

O melhor resultado obtido nos testes com validação cruzada utilizando a fusão das características dos alimentos foi de 96,39% de taxa de acerto.

#### 4.3.1 Discussão dos Testes com Validação Cruzada Utilizando o Conjunto de Dados Ampliado

Para uma análise mais aprofundada da rede Bayesiana nos testes com validação cruzada utilizando o conjunto de dados ampliado, o teste que obteve melhor resultado foi analisado, ou seja, o “Teste 4” apresentado na TABELA 15.

Esse teste obteve uma taxa de acerto de 96,39%, isto é, das 1440 amostras testadas, 1388 foram classificadas corretamente e 52 foram classificadas incorretamente. A TABELA 16 mostra os alimentos testados e suas respectivas taxas de acerto.

TABELA 16 – ALIMENTOS TESTADOS E SUAS TAXAS DE ACERTO NO TESTE REALIZADO COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO

Alimento	Quantidade de Amostras Testadas	Quantidade de Amostras Classificadas Corretamente	Quantidade de Amostras Classificadas Incorretamente	Percentual de Amostras Classificadas Corretamente
Alface	90	90	0	100%
Almôndega	90	85	5	94,44%
Arroz Branco	90	90	0	100%
Batata Frita	90	89	1	98,89%
Beterraba	90	89	1	98,89%
Bife Bovino na Chapa	90	88	2	97,78%
Carne Bovina de Panela	90	71	19	78,89%
Cenoura	90	89	1	98,89%
Feijão Carioca	90	89	1	98,89%
Macarrão	90	90	0	100%
Maionese	90	84	6	93,33%
Peito de Frango a Milanese	90	87	3	96,67%
Purê de Batatas	90	87	3	96,67%
Estrogonofe de Carne	90	87	3	96,67%
Estrogonofe de Frango	90	87	3	96,67%
Tomate	90	86	4	95,56%
TOTAL	1440	1388	52	96,39%

FONTE: O autor (2015)



No teste em questão, dos 16 tipos de alimentos testados, 3 tiveram uma classificação de 100%, isto é, das 90 amostras de cada um destes alimentos, todas as 90 foram classificadas corretamente. Estes alimentos são: alface, arroz branco e macarrão.

Já a pior classificação foi do alimento carne bovina de panela, com um resultado de 78,89% de amostras classificadas corretamente, isto é, das 90 amostras testadas, 71 foram classificadas corretamente e 19 foram classificadas incorretamente. A FIGURA 46 apresenta a matriz de confusão do teste em questão.

a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	<-- classificação
90	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a = Alface
0	85	0	0	0	2	3	0	0	0	0	0	0	0	0	0	b = Almôndega
0	0	90	0	0	0	0	0	0	0	0	0	0	0	0	0	c = Arroz Branco
0	0	0	89	0	0	0	0	0	0	0	0	0	0	0	1	d = Batata Frita
0	1	0	0	89	0	0	0	0	0	0	0	0	0	0	0	e = Beterraba
0	1	0	0	0	88	1	0	0	0	0	0	0	0	0	0	f = Bife Bovino na Chapa
0	13	0	0	0	0	71	0	0	0	0	0	0	6	0	0	g = Carne Bovina de Panela
0	0	0	0	0	0	1	89	0	0	0	0	0	0	0	0	h = Cenoura
0	0	0	0	0	0	0	0	89	0	0	0	0	1	0	0	i = Feijao Carioca
0	0	0	0	0	0	0	0	0	90	0	0	0	0	0	0	j = Macarrão
0	0	0	0	0	0	0	0	0	0	84	0	6	0	0	0	k = Maionese
0	0	0	0	0	3	0	0	0	0	0	87	0	0	0	0	l = Peito de Frango à Milanese
0	0	0	0	0	0	0	0	0	0	3	0	87	0	0	0	m = Purê de Batatas
0	0	0	0	0	0	3	0	0	0	0	0	87	0	0	0	n = Estrogonofe de Carne
0	0	0	0	0	0	0	0	0	0	0	0	2	87	1	0	o = Estrogonofe de Frango
0	1	0	0	0	0	3	0	0	0	0	0	0	0	0	86	p = Tomate

FIGURA 46 – MATRIZ DE CONFUSÃO DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO  
FONTE: O autor (2015)

Conforme é possível observar na matriz de confusão na FIGURA 46, no teste em questão, o pior resultado foi do alimento carne bovina de panela, que das 90 amostras testadas, 13 foram classificadas como almôndega e 6 foram classificadas como estrogonofe de carne.

A aplicação WEKA calcula automaticamente a área sob a curva ROC, a sensibilidade e a especificidade de cada alimento nos testes efetuados. A TABELA 17 apresenta esses valores para o teste em questão.

TABELA 17 – ALIMENTOS TESTADOS E SUAS RESPECTIVAS ÁREAS SOB A CURVA ROC, SENSIBILIDADES E ESPECIFICIDADES DO TESTE REALIZADO COM VALIDAÇÃO CRUZADA UTILIZANDO O CONJUNTO DE DADOS AMPLIADO

Alimento	Área sob a curva ROC	Sensibilidade	Especificidade
Alface	1	1	0
Almôndega	0,995	0,944	0,012
Arroz Branco	1	1	0
Batata Frita	1	0,989	0
Beterraba	1	0,989	0
Bife Bovino na Chapa	0,999	0,978	0,004
Carne Bovina de Panela	0,993	0,789	0,008
Cenoura	1	0,989	0
Feijão Carioca	1	0,989	0
Macarrão	1	1	0
Maionese	0,999	0,933	0,002
Peito de Frango a Milanesa	1	0,967	0
Purê de Batatas	0,999	0,967	0,004
Estrogonofe de Carne	0,998	0,967	0,007
Estrogonofe de Frango	1	0,967	0
Tomate	0,998	0,956	0,001
MÉDIA TOTAL	0,999	0,964	0,002

FONTE: O autor (2015)

Conforme apresenta a TABELA 17, a sensibilidade média da rede é de 0,964, mostrando uma alta probabilidade da rede para classificar corretamente os alimentos. A especificidade média da rede é de 0,002, mostrando a baixa probabilidade da rede para classificar incorretamente os alimentos.

A área sob a curva ROC do alimento que apresentou a pior taxa de acerto (carne bovina de panela) é de 0,993 e a média da área sob a curva ROC de todos os alimentos testados é de 0,999. Esses valores, por estarem próximos do valor 1, indicam que a rede Bayesiana utilizada neste teste possui um alto grau de confiabilidade.

No teste realizado utilizando um conjunto de teste fornecido, apresentado no capítulo 4.2, o alimento com menor taxa de acerto foi arroz branco, com um percentual de amostras classificadas corretamente de 60,0%. Já o teste realizado utilizando o conjunto de dados ampliado obteve um resultado de 100% de amostras classificadas corretamente para este alimento.

Além disso, o teste efetuado no capítulo 4.2 apresentou um resultado de 90,42% de amostras classificadas corretamente, já o teste apresentado neste capítulo obteve um resultado de 96,39% de amostras classificadas corretamente. Com isso, observa-se uma melhora nos resultados a medida que se tem mais amostras diferentes para o treinamento da rede.

Sendo assim, o ideal é que cada novo conjunto de dados obtido possa ser integrado ao treinamento da rede Bayesiana.

#### 4.4 Trabalho Relacionado

No sistema apresentado neste trabalho, a aquisição da imagem ocorre a partir de uma foto obtida por uma câmera sobre o prato, em um ângulo de 90°, a uma distância aproximada de 45cm. Já no DietCam, sistema desenvolvido para iPhone® por Kong e Tan (2012), a aquisição da imagem do alimento ocorre a partir de 3 fotos tiradas ao redor do prato em um ângulo aproximado de 120°, ou com um pedaço de vídeo obtido nessas mesmas condições.

A TABELA 18 apresenta algumas comparações entre o sistema apresentado neste trabalho e o sistema DietCam.

TABELA 18 – COMPARATIVO ENTRE O SISTEMA APRESENTADO NESTE TRABALHO E O SISTEMA DIETCAM

	Sistema deste Trabalho	DietCam
Desenvolvimento	MATLAB®	iPhone®
Base de Dados	16 alimentos	7 alimentos
Aquisição da Imagem	1 foto (90°)	3 fotos ou vídeo (120°)
Pré-Processamento	TCH e condição lógica	Não faz
Segmentação	Crescimento de região	Comparação entre as características da imagem e as características da base de dados
Características	Cor e textura LPQ	SIFT
Classificação	Redes Bayesianas	Teorema de Bayes
Estimativa do Volume e Cálculo de Calorias	Não faz	Reconstrução 3D
Resultado Médio	96,26%	92%

FONTE: O autor (2015)

Conforme mostra a TABELA 18, o sistema apresentado neste trabalho utilizou 16 alimentos diferentes para a base de dados, enquanto o DietCam utilizou 7 alimentos. Os alimentos utilizados para a base de dados do DietCam foram:

- maçã;
- banana;
- hambúrguer;
- bife bovino;
- sanduiche;
- laranja;
- pera.

O sistema apresentado neste trabalho utiliza a técnica de crescimento de região em diferentes planos da imagem para segmentar os alimentos, e utiliza um vetor de características, gerado a partir da cor e da textura da imagem, analisado por uma rede Bayesiana para realizar a classificação dos alimentos. Já o DietCam utiliza as características SIFT para segmentar e classificar os alimentos, comparando essas características com outras armazenadas em uma base de dados, utilizando cálculos baseados no teorema de Bayes.

A taxa média de acerto para a classificação dos alimentos nos testes efetuados no DietCam foi de 92%, e a avaliação do desvio padrão mostrou erros de aproximadamente 20% para a estimativa do volume. Já o sistema apresentado neste trabalho, apesar de não realizar a estimativa do volume e o cálculo calórico, apresentou um resultado final médio de 96,26% de acerto para a classificação dos alimentos.

## 5 CONCLUSÃO

Uma alimentação saudável é um dos principais fatores para reduzir o risco de obter doenças crônicas não transmissíveis, tais como obesidade, hipertensão e diabetes. Pensando nisso, idealizou-se um sistema capaz de analisar os valores calóricos das refeições consumidas por um indivíduo, utilizando uma imagem obtida através de uma câmera digital ou celular, com a finalidade de auxiliar a obtenção de dados referentes à alimentação do indivíduo, possibilitando um rápido diagnóstico e a intervenção nutricional a fim de contribuir para a saúde e qualidade de vida.

O sistema apresentado neste trabalho é uma parte do sistema idealizado, com a capacidade de segmentar e classificar diferentes alimentos em imagens de porções alimentares, utilizando redes Bayesianas. Nessa etapa, o sistema ainda não possui a capacidade de detectar a sobreposição e/ou a mistura dos alimentos, por isso há a necessidade de que os alimentos estejam devidamente separados no prato.

Da grande variedade de alimentos que podem ser encontrados em restaurantes, apenas dezesseis deles foram selecionados para a realização deste trabalho. Porém estes alimentos foram selecionados de diferentes grupos da pirâmide alimentar, e são considerados alimentos típicos consumidos pela população brasileira.

Cor e textura foram as características avaliadas e definidas como as mais relevantes presentes em imagens de porções alimentares. Para definir a textura, foi utilizado o histograma LPQ da imagem do alimento. Já para a cor, foram utilizadas as médias e os desvios padrão dos planos vermelho, verde, azul e matiz da imagem. Estes planos, juntamente com a técnica de crescimento de região, foram utilizados para segmentar os alimentos presentes no prato.

As características de cor dos alimentos foram representadas por um vetor de 8 posições, sendo estas posições, a média e o desvio padrão dos valores dos pixels nos planos vermelho, verde, azul e matiz da imagem.

As características de textura dos alimentos foram representadas por um histograma, ou seja, um vetor de 255 posições obtido através do descritor de textura LPQ.

Essas características foram extraídas de cada alimento da base de dados, e fundidas em um vetor único de características, com 263 posições, a fim de treinar uma rede Bayesiana com a capacidade de classificar os alimentos.

Uma análise realizada na rede Bayesiana, listou a ordem de importância das características utilizadas no trabalho para a classificação dos alimentos. Nessa lista as 5 características com maior grau de importância foram: média no plano verde, média no plano vermelho, média no plano matiz, desvio padrão do plano vermelho e a posição 108 do histograma LPQ.

Conforme testes apresentados, a fusão das características de cor e textura se mostrou mais eficiente que a utilização dessas características separadamente.

Com a utilização de técnicas de avaliação por validação cruzada e conjunto de teste fornecido, foram realizados diversos testes na rede Bayesiana para analisar a eficácia do sistema proposto.

Com a técnica de validação cruzada, utilizando apenas as características relacionadas à cor dos alimentos, obteve-se um resultado médio de 93,68%. Utilizando apenas as características relacionadas à textura dos alimentos, obteve-se um resultado médio de 93,23%. E utilizando a fusão das características de cor e textura dos alimentos, obteve-se um resultado médio de 95,63%.

Na análise realizada com um conjunto de teste fornecido, duas bases de dados distintas foram utilizadas. As características extraídas de imagens contendo apenas um tipo de alimento no prato foram utilizadas para o treinamento da rede, e as características extraídas de imagens contendo diversos tipos de alimentos no prato foram utilizadas para teste, totalizando 1200 amostras para treinamento e 240 amostras para os testes. Esse teste obteve um resultado de 90,42%, isto é, apenas 23 dos 240 alimentos testados foram classificados de forma incorreta.

As amostras utilizadas no teste realizado com um conjunto de teste fornecido foram agregadas às amostras do conjunto de treinamento, formando um único conjunto de dados para o treinamento da rede Bayesiana, chamado de conjunto de dados ampliado.

Testes utilizando a técnica de validação cruzada foram realizados na rede Bayesiana treinada com o conjunto de dados ampliado, e o resultado médio desses testes foi de 96,26% de amostras classificadas corretamente. Comparando estes resultados ao resultado obtido anteriormente no teste realizado com um conjunto de teste fornecido, com 90,42% de amostras classificadas corretamente, verifica-se que

a rede Bayesiana necessita estar em constante atualização da base dados de treinamento sempre que novos dados forem adquiridos, a fim de manter a qualidade dos resultados.

No melhor teste realizado com a técnica de validação cruzada no conjunto de dados ampliado, obteve-se uma taxa de acerto de 96,39%. Nesse teste a sensibilidade, a especificidade e área sob a curva ROC de cada alimento foi calculada. A sensibilidade média da rede foi de 0,964, mostrando uma alta probabilidade da rede para classificar corretamente os alimentos. A especificidade média da rede foi de 0,002, mostrando a baixa probabilidade da rede para classificar incorretamente os alimentos. E a média da área sob a curva ROC foi de 0,999, e por estar próximo do valor 1, esse valor indica que a rede Bayesiana utilizada neste trabalho possui um alto grau de confiabilidade.

Por fim, avaliando a metodologia proposta e os resultados obtidos, conclui-se que o sistema apresentado é capaz de segmentar e classificar diferentes tipos de alimentos através das características de cor e textura.

## 5.1 TRABALHOS FUTUROS

Como trabalho futuro, idealiza-se o desenvolvimento de um sistema capaz de calcular o valor calórico dos alimentos no prato, mas para isso, será necessário estudar métodos para estimar o volume de cada alimento utilizando a imagem bidimensional.

Também há a necessidade de aumentar a base de dados, tanto para um grupo maior de alimentos, quanto para o número maior de amostras de um mesmo alimento. Além de fazer com que o sistema possua a capacidade de analisar porções alimentares com sobreposição e mistura de alimentos.

## REFERÊNCIAS

ADAMS, R.; BISCHOF, L. Seeded region growing. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 16, n. 6, p. 641–647, 1994.

ALVES, V. L. S.; CUNHA, I. C. K. O.; MARIN, H. F.; DE OLIVEIRA, O. Criação de um web site para enfermeiros sobre pé diabético. **ACTA Paulista de Enfermagem**, v. 19, n. 1, p. 56–61, 2006.

ANÇÃO, M. S. Informática em Terapia Nutricional. **MAGNONI, D.; CUKIER, C. - Perguntas e Respostas em Nutrição Clínica**. 1ª ed., p.361–364, 2001. Editora Roca.

ASSIS, C. M. DE; QUIO, V. R.; RASSELLI, J. G.; CUNHA, F. G. C. DA; SALAROLI, L. B. Eating habits and nutritional status of the youth: a comparative study. **Nutrire Rev. Soc. Bras. Aliment. Nutr**, v. 34, n. 1, p. 13–27, 2009.

ATHERTON, T.; KERBYSON, D. Size invariant circle detection. **Image and Vision computing**, v. 17, n. February 1997, p. 795–803, 1999.

BERMUDEZ, O.; TUCKER, K. Trends in dietary patterns of Latin American populations. **Cad. de Saúde Pública**, v. 19, p. 87–99, 2003.

BERNER, E. S. **Clinical Decision Support Systems: theory and practice**. Springer-Verlag, 1999.

BOUCKAERT, R. R.; FRANK, E.; HALL, M.; et al. WEKA Manual for Version 3-6-5. Disponível em: <<http://ufpr.dl.sourceforge.net/project/weka/documentation/3.6.x/WekaManual-3-6-5.pdf>>. Acesso em: 20/8/2014.

BRASIL. MINISTÉRIO DA SAÚDE. **Plano de ações estratégicas para o enfrentamento das doenças crônicas não transmissíveis (DCNT) no Brasil 2011-2022**. 1ª ed. Ministério da Saúde, 2011.

CHARLES POYNTON. **Digital Video and HDTV: Algorithms and Interfaces**. 1ª ed. MORGAN KAUFMANN PUBLISHERS, 2003.

CHARNIAK, E. Bayesian Networks without Tears. **AI Magazine**, v. 12, n. 4, p. 50, 1991.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, 1991.

CONGALTON, R. G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. Lewis Publishers, 1999.



COOPER, G. F.; HERSKOVITS, E. A Bayesian method for the induction of probabilistic networks from data. **Machine Learning**, v. 9, n. 4, p. 309–347, 1992. Kluwer Academic Publishers.

CUPPARI, L. **Nutrição Clínica no Adulto**. 2nd ed. São Paulo, 2002.

D'ORAZIO, T.; GUARAGNELLA, C.; LEO, M.; DISTANTE, A. A new algorithm for ball recognition using circle Hough transform and neural classifier. **Pattern Recognition**, v. 37, n. 3, p. 393–408, 2004.

DENG, W.; XIAO, W.; DENG, H.; LIU, J. MRI brain tumor segmentation with region growing method based on the gradients and variances along and inside of the boundary curve. 2010 3rd International Conference on Biomedical Engineering and Informatics. **Anais...** . v. 0, p.393–396, 2010. IEEE. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=5639536>>. Acesso em: 31/8/2015.

DENG, Y.; MANJUNATH, B. S.; SHIN, H. Color Image Segmentation. **Proc. of 1999 International Conf. on Computer Vision and Pattern Recognition (ACCV'98)**, v. 1, n. 1, p. 6, 1999.

DEPARTMENT OF COMPUTER SCIENCE AND ENGINEERING. CMV/Research/NewTextureDescriptors. **Department of Computer Science and Engineering**, 2011. Disponível em: <<http://www.cse.oulu.fi/CMV/Research/NewTextureDescriptors>>. Acesso em: 1/2/2015.

DIAS, J. S. **Raciocínio Médico e Abordagem Bayesiana: Um Estudo de Caso (Tese para professor titular)**, 2004. PUC-PR.

FACON, J. **Morfologia matemática: teoria e exemplos**. 1st ed. Curitiba: Editora Universitária Champagnat da Pontifícia Universidade Católica do Paraná, 1996.

FILHO, M. B.; RISSIN, A. A transição nutricional no Brasil: tendências regionais e temporais. **Cad. de Saúde Pública**, v. 19, p. 181–191, 2003.

FISBERG, R. M.; SLATER, B.; MARCHIONI, D. M. L.; MARTINI, L. A. **Inquéritos Alimentares - Métodos e Bases Científicos**. 1st ed. São Paulo: Editora Manole, 2005.

GAAG, L. C. VAN DER. Bayesian belief networks: odds and ends. **The Computer Journal**, v. 39(2), p. 97–113, 1996.

GIGLI, G.; BOSSE, E.; LAMPROPOULOS, G. A. An optimized architecture for classification combining data fusion and data-mining. **Information Fusion**, v. 8, n. 4, p. 366–378, 2007.

GIORDANENGO, T. Procédures d' évaluation de la composition chimique du bois par spectrométrie proche infrarouge. **Rapport de DEA Sciences du Bois**, 2005.

GOLDSCHMIDT, R.; PASSOS, E. **Data Mining: Um Guia Prático**. 1st ed. São Paulo: Elsevier Editora, 2005.

GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. Prentice Hall, 2007.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 6, p. 610–621, 1973.

HARALICK, R. M.; SHAPIRO, L. G. **Computer and Robot Vision**. 1ª ed. Addison-Wesley Publ. Comp., 1992.

HECKERMAN, D. Bayesian Networks for Data Mining. **Data Mining and Knowledge Discovery**, v. 119, n. 1, p. 79–119, 1997. Springer Netherlands.

HICKLIN, A.; ULERY, B.; WATSON, C. A Brief Introduction to Biometric Fusion. **Falls Church: Noblis**, v. 1, n. 1, p. 10, 2006.

HOLANDA, L. B.; FILHO, A. DE A. B. Métodos aplicados em inquéritos alimentares. **Rev Paul Pediatría**, v. 24, n. 1, p. 62–70, 2006.

IBGE. Pesquisa de Orçamentos Familiares: 2008-2009. Análise do Consumo Alimentar Pessoal no Brasil. **Biblioteca do Ministério do Planejamento, Orçamento e Gestão**, p. 150, 2010. Disponível em: <[http://www.ibge.gov.br/home/estatistica/populacao/condicaodevida/pof/2008\\_2009\\_analise\\_consumo/pofanalise\\_2008\\_2009.pdf](http://www.ibge.gov.br/home/estatistica/populacao/condicaodevida/pof/2008_2009_analise_consumo/pofanalise_2008_2009.pdf)>. Acesso em: 20/2/2015.

KALLERGI, M.; WOODS, K.; CLARKE, L. P.; QIAN, W.; CLARK, R. A. Image segmentation in digital mammography: Comparison of local thresholding and region growing algorithms. **Computerized Medical Imaging and Graphics**, v. 16, n. 5, p. 323–331, 1992.

KELLNER, D. Region Growing (2D/3D grayscale). Disponível em: <<http://www.mathworks.com/matlabcentral/fileexchange/32532-region-growing--2d-3d-grayscale->>. Acesso em: 17/9/2014.

KIM, S. Y.; KIM, S. M. Energy intake and snack choice by the meal patterns of employed people. **Nutrition Research and Practice**, v. 4, n. 1, p. 43–50, 2010.

KOEHLER, C. Desenvolvimento de um Sistema Inteligente para Apoio à Decisão em Saúde. **Universidade de Caxias do Sul**, v. 1, n. 1, p. 8, 2002.

KONG, F.; TAN, J. DietCam: Automatic dietary assessment with mobile camera phones. **Pervasive and Mobile Computing**, v. 8, n. 1, p. 147–163, 2012.

KUNCHEVA, L. I. **Combining Pattern Classifiers**. 1ª Ed. ed. Wiley-Interscience, 2004.

LEI, Z.; LI, S. Z. Fast multi-scale local phase quantization histogram for face recognition. **Pattern Recognition Letters**, v. 33, n. 13, p. 1761–1767, 2012. Elsevier B.V.

LEUNG, M.; HUANG, T. Detecting the wheel pattern of a vehicle using stereo images. **Pattern recognition**, v. 24, n. 12, p. 1139–1151, 1991.

LEVINE, R. I.; DRANG, D. E.; EDELSON, B. **Inteligência Artificial e Sistemas Especialistas**. 1ª ed. McGraw-Hill, Inc, 1988.

LIANG, T.; DAVIER, A. VON. Cross-Validation An Alternative Bandwidth-Selection Method in Kernel Equating. **Applied Psychological Measurement**, v. 38, p. 281–295, 2014.

LOPES, J. M. B. **Cor e Luz**. 3rd ed. Lisboa: Instituto Superior Técnico - Universidade Técnica de Lisboa, 2013.

LOWE, D. G. Object recognition from local scale-invariant features. **Proceedings of the Seventh IEEE International Conference on Computer Vision**, v. 2, n. 1, 1999.

MACEDO, M. M. G. **Detecção e extração de redes vasculares usando a transformada de Hough**, 2012. Universidade de São Paulo.

MALTA, D. C.; CEZÁRIO, A. C.; MOURA, L.; NETO, O. L. DE M.; JUNIOR, J. B. DA S. A construção da vigilância e prevenção das doenças crônicas não transmissíveis no contexto do Sistema Único de Saúde. **Epidemiol. Serv. Saúde**, v. 15, n. 3, p. 47–65, 2006.

MALTA, D. C.; MORAIS NETO, O. L. DE; SILVA JUNIOR, J. B. DA. Apresentação do plano de ações estratégicas para o enfrentamento das doenças crônicas não transmissíveis no Brasil, 2011 a 2022. **Epidemiologia e Serviços de Saúde**, 2011.

MALTONI, D.; MAIO, D.; JAIN, A. K.; PRABHAKAR, S. **Handbook of Fingerprint Recognition**. Springer-Verlag New York Inc, 2009.

MARTINEZ, E. Z.; LOUZADA-NETO, F.; PEREIRA, B. DE B. A Curva ROC para Testes Diagnósticos. **Cadernos Saúde Coletiva**, v. 11, n. 1, p. 7–31, 2003.

MASSAD, E.; MENEZES, R. X. DE; SILVEIRA, P. S. P.; ORTEGA, N. R. S. **Métodos Quantitativos em Medicina**. 1ª ed. Editora Manole, 2004.

MCCORMICK, C. K-fold Cross-Validation, with MATLAB code. Disponível em: <<https://chrisjmccormick.wordpress.com/2013/07/31/k-fold-cross-validation-with-matlab-code/>>. Acesso em: 20/3/2015.

NANNI, L.; BRAHNAM, S.; LUMINI, A. A very high performing system to discriminate tissues in mammograms as benign and malignant. **Expert Systems with Applications**, v. 39, n. 2, p. 1968–1971, 2012. Elsevier Ltd.

NORSYS SOFTWARE CORP. **Netica - Application for Belief Networks and Influence Diagrams - User's Guide**. 1997.

OJANSIVU, V.; HEIKKILÄ, J. Blur insensitive texture classification using local phase quantization. **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**, v. 5099 LNCS, p. 236–243, 2008.

OLIVEIRA, R. A transição nutricional no contexto da transição demográfica e epidemiológica. **Rev. Min. Saúde Públ.**, v. 3, n. 5, p. 16–23, 2004.

OPAS. Vigilância em DCNT e fatores de risco. Disponível em: <[http://www.paho.org/bra/index.php?option=com\\_content&view=article&id=572:vigilancia-dcnt-fatores-risco&catid=901:bra-03-a-doencas-nao-transmissiveis&Itemid=539](http://www.paho.org/bra/index.php?option=com_content&view=article&id=572:vigilancia-dcnt-fatores-risco&catid=901:bra-03-a-doencas-nao-transmissiveis&Itemid=539)>. Acesso em: 14/2/2015.

PARANÁ. Lei no 17604, de 19 de junho de 2013. Dispõe sobre a obrigatoriedade da especificação e divulgação da quantidade de calorias, presença de glúten e lactose nos cardápios de bares, restaurantes, hotéis, fast-foods e similares. **Diário Oficial Executivo [do Parana]**, v. 1, n. 8981, p. 3, 2013.

PAVLIDIS, T. Structural Pattern Recognition. **Springer Series in Elektrophysics**, p. 4–8, 1977.

PEARL, J. **Causality: Models, Reasoning, and Inference**. 1ª ed. Cambridge: Cambridge University Press, 2000.

PHILIPPI, S. T. **Pirâmide dos alimentos. Fundamentos básicos da nutrição**. 2nd ed. Editora Manoli, 2008.

PHILIPPI, S. T.; LATTERZA, A. R.; CRUZ, A. T. R.; RIBEIRO, L. C. Pirâmide alimentar adaptada: guia para escolha dos alimentos. **Revista de Nutrição**, 1999.

REZENDE, S. O. **Sistemas Inteligentes - Fundamentos e Aplicações**. 1ª ed. Editora Manole, 2003.

RICH, E.; KNIGHT, K. **Artificial Intelligence**. McGraw-Hill Publishing Co., 1991.

RUSS, J. C. **The Image Processing Handbook**. 6ª ed. CRC Press, 2011.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**, 3rd edition. Pearson Higher Education, 2009.

SAHEKI, A. H. **Construção de uma rede bayesiana aplicada ao diagnóstico de doenças cardíacas**, 2005. Escola Politécnica da Universidade de São Paulo.

SEVERINO, O. **Mistura de cores: Uma nova abordagem para processamento de cores e sua aplicação na segmentação de imagens**, 2009. Escola de Engenharia de São Carlos da Universidade de São Paulo, Brasil.

SHAPIRO, L.; STOCKMAN, G. **Computer Vision**. Prentice Hall, 2001.

SHIGA, Y. M.; COELHO, K. S.; DIAS, J. S.; FERRARI, G. L. Algoritmo de estratificação de porções alimentares baseado em imagem. **Congresso Brasileiro de Engenharia Biomédica**, p. 650–653, 2014.

SILVA, A. C. Algoritmos para Diagnóstico Assistido de Nódulos Pulmonares Solitários em Imagens de Tomografia Computadorizada. **Rio de Janeiro: PUC**, v. 1, n. 1, 2004.

SIMAS, R. C. **Determinação de proteína bruta e aminoácidos em farelo de soja por espectroscopia no infravermelho próximo**, 2005. Universidade Estadual de Campinas.

SOILLE, P. **Morphological Image Analysis: Principles and Applications**. 1999.

SOTELO, F. F. **Aplicação da espectroscopia de infravermelho próximo na caracterização de petróleo**, 2006. Universidade de São Paulo.

SOUTO, R. P. Segmentação de imagem multiespectral utilizando-se o atributo matiz. **São José dos Campos - INPE**, v. 1, n. 1, 2000.

TU, S. W.; KEMPER, C. A.; LANE, N. M.; CARLSON, R. W.; MUSEN, M. A. A methodology for determining patients' eligibility for clinical trials. **Methods of Information in Medicine**, v. 32, n. 4, p. 317–325, 1993.

VASCONCELOS, F. DE A. G. O nutricionista no Brasil: uma análise histórica. **Revista de Nutricao**, v. 15, n. 2, p. 127–138, 2002.

WELSH, S.; DAVIS, C.; SHAW, A. A Brief History of Food Guides in the United States. **Nutrition Today**, 1992.

WHO. Global action plan for the prevention and control of noncommunicable diseases 2013-2020. **World Health Organization**, v. 1, p. 47, 2013. Disponível em: <[http://apps.who.int/iris/bitstream/10665/94384/1/9789241506236\\_eng.pdf](http://apps.who.int/iris/bitstream/10665/94384/1/9789241506236_eng.pdf)>. Acesso em: 5/1/2015.

WHO/FAO. Diet, nutrition and the prevention of chronic diseases. Report of a Joint WHO/FAO Expert Consultation. **World Health Organization**, v. 1, p. 149, 2003. Disponível em: <[http://whqlibdoc.who.int/trs/who\\_trs\\_916.pdf](http://whqlibdoc.who.int/trs/who_trs_916.pdf)>. Acesso em: 5/1/2015.

WITTEN, I. . H.; FRANK, E. **Data Mining: Practical machine learning tools and techniques**. 2005.

WU, J.; POEHLMAN, S.; NOSEWORTHY, M. D.; KAMATH, M. V. Texture Feature based Automated Seeded Region Growing in Abdominal MRI Segmentation. 2008 International Conference on BioMedical Engineering and Informatics. **Anais...** . p.263–267, 2008. IEEE. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4549175>>. Acesso em: 31/8/2015.

XIAO, Q. Biometrics-technology, application, challenge, and computational intelligence solutions. **IEEE Computational Intelligence Magazine**, v. 2, n. 2, 2007.

YANO, V. A. N. **Sistema biométrico multimodal baseado em pupilometria dinâmica**, 2011.

ZEFERINO, A.; FILHO, A. B. Acompanhamento do crescimento. **Jornal de pediatria**, v. 79, p. 23–32, 2003.

## APÊNDICE



FIGURA 47 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ALFACE  
FONTE: O autor (2015)



FIGURA 48 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ALMÔNDEGA  
FONTE: O autor (2015)



FIGURA 49 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ARROZ BRANCO  
FONTE: O autor (2015)





FIGURA 50 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO BATATA FRITA  
FONTE: O autor (2015)



FIGURA 51 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO BETERRABA  
FONTE: O autor (2015)



FIGURA 52 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO BIFE BOVINO NA  
CHAPA  
FONTE: O autor (2015)





FIGURA 53 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO CARNE BOVINA DE PANELA  
FONTE: O autor (2015)



FIGURA 54 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO CENOURA  
FONTE: O autor (2015)




FIGURA 55 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO FEIJÃO CARIOCA  
FONTE: O autor (2015)



FIGURA 56 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO MACARRÃO  
FONTE: O autor (2015)




FIGURA 57 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO MAIONESE  
FONTE: O autor (2015)




FIGURA 58 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO PEITO DE FRANGO À MILANESA  
FONTE: O autor (2015)



FIGURA 59 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO PURÊ DE BATATAS  
FONTE: O autor (2015)



FIGURA 60 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ESTROGONOFE DE  
CARNE  
FONTE: O autor (2015)



FIGURA 61 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO ESTROGONOFE DE  
FRANGO  
FONTE: O autor (2015)





FIGURA 62 – PRATOS COM DIFERENTES QUANTIDADES DO ALIMENTO TOMATE  
FONTE: O autor (2015)



FIGURA 63 – PRATOS COM DIVERSOS ALIMENTOS  
FONTE: O autor (2015)

A base de dados adquirida para a realização deste trabalho está disponibilizada no link [https://github.com/yurishiga/bd\\_porcoes\\_alimentares](https://github.com/yurishiga/bd_porcoes_alimentares).